


UNIVERSIDADE FEDERAL DO PARANÁ

DYEISON CESAR MLENEK

MÉTODOS SEMIAUTOMÁTICOS PARA CONTAGEM DE ÁRVORES EM
PLANTIOS DE *Pinus taeda* L., DERIVADOS DE DADOS LIDAR
AEROTRANSPORTADO

CURITIBA

2020



DYEISON CESAR MLENEK

MÉTODOS SEMIAUTOMÁTICOS PARA CONTAGEM DE ÁRVORES EM
PLANTIOS DE *Pinus taeda* L., DERIVADOS DE DADOS LIDAR
AEROTRANSPORTADO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Engenharia Florestal.

Orientadora:
Prof^ª. Dr^ª. Ana Paula Dalla Corte

Coorientadores:
Prof. Dr. Daniel Rodrigues dos Santos
Prof. Dr. Carlos Roberto Sanquetta

CURITIBA

2020

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Mlenek, Dyeison Cesar

Métodos semiautomáticos para contagem de árvores em plantios de *Pinus taeda* L., derivados de dados LiDAR aerotransportado / Dyeison Cesar Mlenek. - Curitiba, 2020.

99 f. : il.

Orientadora: Profa. Dra. Ana Paula Dalla Corte

Coorientadores: Prof. Dr. Daniel Rodrigues dos Santos

Prof. Dr. Carlos Roberto Sanquetta

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 30/06/2020.

Área de concentração: Manejo Florestal.

1. Mapeamento florestal. 2. Levantamentos florestais. 3. Fotogrametria aérea. 4. Sensoriamento remoto. 5. Algoritmos. 6. Lasers. 7. *Pinus taeda*. 8. Teses. I. Dalla Corte, Ana Paula. II. Santos, Daniel Rodrigues dos. III. Sanquetta, Carlos Roberto. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD – 634.9

CDU – 634.0.58

Bibliotecária: Berenice Rodrigues Ferreira – CRB 9/1160

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **DYEISON CESAR MLENEK** intitulada: **MÉTODOS SEMIAUTOMÁTICOS PARA A CONTAGEM DE ÁRVORES EM PLANTIOS DE *Pinus taeda* L., DERIVADOS DE DADOS LIDAR AEROTRANSPORTADO**, sob orientação da Profa. Dra. ANA PAULA DALLA CORTE, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa. A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 30 de Junho de 2020.

Assinatura Eletrônica

01/07/2020 19:23:08.0

ANA PAULA DALLA CORTE

Presidente da Banca Examinadora (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

01/07/2020 13:58:20.0

VAGNER ALEX PESCK

Avaliador Externo (UNIVERSIDADE ESTADUAL DO CENTRO-OESTE)

Assinatura Eletrônica

01/07/2020 14:37:30.0

ALLAN LIBANIO PELISSARI

Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Dedico, a todos, que porventura estejam lendo este documento, em busca
de conhecimento ou aprimoramento intelectual.

AGRADECIMENTOS

Agradeço primeiramente a Deus, o grande geômetra do universo, por me proporcionar desafios cada vez maiores.

A minha família, na figura dos meus pais, Bronislau e Eva e minha irmã Stephany, por terem me incentivado durante todo o período.

Ao meu comitê orientador, composto pela professora Dra. Ana Paula Dalla Corte e pelos professores Dr. Daniel Rodrigues dos Santos e Dr. Carlos Roberto Sanquetta pela confiança em minha capacidade para o desenvolvimento deste trabalho.

A empresa Klabin S.A. pela apresentação de uma demanda interna e fornecimento dos dados utilizados na realização deste trabalho.

Ao Instituto Tecnológico de Transportes e Infraestrutura (ITTI) da Universidade Federal do Paraná (UFPR) e a Fundação de Pesquisas Florestais do Paraná (FUPEF), por proporcionar o desenvolvimento deste trabalho em conjunto com as minhas obrigações laborais, instituições responsáveis pelo meu desenvolvimento pessoal e profissional, qual sou eternamente grato, principalmente a todos que fazem ou fizeram parte desta maravilhosa equipe multidisciplinar.

Aos amigos doutores: Eduardo Ratton, Durval Nascimento Neto, Carlos Aurélio Nadal, Donizeti Antonio Giusti, Sandra Ramos, Lucas Batista Crivellari, amigos mestres: Jonathan Tilio Zonta, João Vinicius Sachet, amigos engenheiros: Leonardo de Marino Treml, Pedro Pompilio, Alexandre Samuel Ramalho, Luís Fernando Silva, e demais amigos, pela troca de experiências que motivaram ou auxiliaram no desenvolvimento deste trabalho.

Ao Dr. Dartagnan Baggio Emerenciano, por toda a confiança depositada em meu trabalho, pela motivação e por todo o suporte essencial para a conclusão deste.

E a todos que de alguma forma contribuíram para este trabalho.

“Digo-lhes hoje, meus amigos, que, apesar das dificuldades e frustrações do momento, eu ainda tenho um sonho. ”
(Martin Luther King Jr., 1963)

RESUMO

Atualmente demanda-se por metodologias que determinem com acurácia o número de árvores, em povoamentos de *Pinus taeda* L., com idades próximas a colheita, visando melhorar as estimativas florestais e reduzir custos relacionados à coleta de dados. Neste trabalho, investigou-se o potencial de três métodos de detecção automática de árvores, em povoamentos florestais de *Pinus taeda* L., com idades de 10 e 15 anos, por meio do uso de dados LiDAR (*Light Detection and Ranging*) aerotransportado de pulsos discretos e baixa densidade de pontos por m² (densidade média, entre 3 e 5 pontos por m²). Para isso métodos automáticos de detecção podem ser aplicados para atender esta demanda. Os métodos de detecção automática estudados foram: filtro de máxima local; filtro de máximos globais; e segmentação por bacias hidrográficas. Os dados foram submetidos a algumas etapas de pré-processamento, como a remoção de *outliers*; a classificação da nuvem de pontos, empregando duas metodologias distintas, o filtro morfológico progressivo e o filtro simulador de tecidos; a normalização das nuvens de pontos e a modelagem digital, a combinação das etapas de pré-processamento resultaram em um conjunto de 15 tipos de dados, utilizados como entrada para os métodos de detecção. Para a verificação da qualidade da detecção de árvores obtida com os algoritmos, foi executado um censo florestal sendo contabilizados os fustes dos talhões em estudo. Os resultados são oriundos de 105 cenários, que consistem na combinação entre algoritmos, parâmetros de detecção e dados de entrada, sendo considerados aderentes aqueles que atingiram acurácia maior que 80%, quando comparados ao censo. Dentre os cenários analisados, nos talhões de 10 anos, apenas 2,9% se comportaram de modo aderente, atingindo uma acurácia média de 88,45%, por meio filtro de máxima local com janela de busca circular, com dimensões inversamente proporcionais à altura e com entrada de dados uma nuvem de pontos não normalizada. Já nos talhões de 15 anos de idade, 9,5% dos cenários foram considerados aderentes, com acurácia média de 93,63%, proporcionada pelo filtro de máxima local com janela de busca, fixa e circular, aplicada a uma nuvem de pontos normalizada e previamente classificada pelo filtro simulador de tecidos. Para a área de estudo e aplicação em ambas as idades, o filtro de máxima local, com janela fixa em formato circular apresentou maior acurácia nas identificações de árvores, 84,02% em média, quando aplicado a um modelo digital de elevação, construído pelo interpolador ponderado ao inverso da distância (*idw*). Visto todos os cenários empregados, conclui-se que atualmente não existe um algoritmo genérico para aplicações em povoamentos florestais de *Pinus taeda* L., com espaçamento regular de 2,5m e com idades de 10 a 15 anos, que apresente alto nível de acurácia.

Palavras-chave: detecção automática de árvores, filtro de máxima local, filtro de máxima global, segmentação de bacias, censo florestal

ABSTRACT

Currently, there is a demand for methodologies that accurately determine the number of trees in stands of *Pinus taeda* L., with ages close to harvest, in order to improve forestry estimates and reduce costs related to data collection. In this work, we investigated the potential of three methods of automatic detection of trees in forest stands of *Pinus taeda* L., aged 10 and 15 years, using LiDAR data (Light Detection and Ranging) airborne pulses discrete and low density of points per m² (average density, between 3 and 5 points per m²). For this purpose, automatic detection methods can be applied to meet this demand. The automatic detection methods studied were: local maximum filter; global maximum filter; and segmentation by hydrographic basins. The data were submitted to some pre-processing steps, such as removing outliers; the classification of the point cloud, using two different methodologies, the progressive morphological filter and the tissue simulator filter; the normalization of point clouds and digital modeling, the combination of the pre-processing steps resulted in a set of 15 types of data, used as input for the detection methods. To verify the quality of the detection of trees obtained with the algorithms, a forest census was carried out, accounting for the shafts of the stands under study. The results come from 105 scenarios, which consist of the combination of algorithms, detection parameters and input data, being considered adherent those that reached accuracy greater than 80%, when compared to the census. Among the scenarios analyzed, in the 10-year plots, only 2.9% behaved in an adherent manner, reaching an average accuracy of 88.45%, using a maximum local filter with a circular search window, with dimensions inversely proportional to the height and with data entry a non-standardized point cloud. In the 15-year-old plots, 9.5% of the scenarios were considered adherent, with an average accuracy of 93.63%, provided by the local maximum filter with a fixed and circular search window, applied to a standardized point cloud. and previously classified by the tissue simulator filter. For the study and application area at both ages, the local maximum filter, with a fixed circular window showed greater accuracy in the identification of trees, 84.02% on average, when applied to a digital elevation model, built by weighted interpolator to the inverse of the distance (idw). Considering all the scenarios employed, it is concluded that currently there is no generic algorithm for applications in forest stands of *Pinus taeda* L., with regular spacing of 2.5m and aged 10 to 15 years, which presents a high level of accuracy.

Keywords: automatic tree detection, local maximum filter, global maximum filter, basin segmentation, forest census

LISTA DE FIGURAS

FIGURA 1 - ELEMENTOS DETERMINANTES DA LARGURA DA FAIXA.....	25
FIGURA 2 - SISTEMA COM RETORNOS DISCRETOS.	26
FIGURA 3 - SISTEMA DE ONDAS COMPLETAS.	26
FIGURA 4 - ELEMENTOS DETERMINANTES DO <i>FOOTPRINT</i>	29
FIGURA 5 - COMPORTAMENTO DO RETORNO DO SINAL.	30
FIGURA 6 – IDENTIFICAÇÃO DO MÁXIMO LOCAL.....	31
FIGURA 7 - PROCESSO DE INUNDAÇÃO EM UM PERFIL TOPOGRÁFICO	32
FIGURA 8 - CONDIÇÃO DE ESPAÇAMENTO	34
FIGURA 9 - REGRA DE ESPAÇAMENTO MÍNIMO	34
FIGURA 10 - LOCALIZAÇÃO DOS TALHÕES COM 10 ANOS DE IDADE.....	36
FIGURA 11 - LOCALIZAÇÃO DOS TALHÕES COM 15 ANOS DE IDADE.....	37
FIGURA 12 - CONJUNTO DE EQUIPAMENTOS UTILIZADOS NO LEVANTAMENTO LIDAR	38
FIGURA 13 - NUVENS DE PONTOS LIDAR DOS TALHÕES COM 10 ANOS DE IDADE	39
FIGURA 14 - NUVENS DE PONTOS LIDAR DOS TALHÕES COM 15 ANOS DE IDADE	40
FIGURA 15 - EXECUÇÃO DO CENSO FLORESTAL.....	41
FIGURA 16 - OPERAÇÃO DE ABERTURA.....	43
FIGURA 17 - OPERAÇÃO DE FECHAMENTO	44
FIGURA 18 - VISÃO GERAL DO FILTRO SIMULADOR DE TECIDOS	45
FIGURA 19 - CONDIÇÃO DE DELAUNAY	48
FIGURA 20 - FILTRO DE MÁXIMA LOCAL, COM JANELA DE BUSCA FIXA.	51
FIGURA 21 - FILTRO DE MÁXIMA LOCAL, COM JANELA DE BUSCA MÓVEL.....	52
FIGURA 22 - SEGMENTAÇÃO POR BACIAS HIDROGRÁFICAS.	53
FIGURA 23 - SEGMENTAÇÃO PELO FILTRO DE MÁXIMOS GLOBAIS	54
FIGURA 24 - SUPERFÍCIE DE DENSIDADE DA NUVEM DE PONTOS LIDAR POR m ² , PARA OS TALHÕES DE 10 ANOS DE IDADE	64
FIGURA 25 - SUPERFÍCIE DE DENSIDADE DA NUVEM DE PONTOS LIDAR POR m ² , PARA OS TALHÕES DE 15 ANOS DE IDADE	64

FIGURA 26 – COMPARATIVO DAS NUVENS CLASSIFICADAS POR ALGORITMOS DISTINTOS E RESPECTIVAS NUVENS NORMALIZADAS, PARA O TALHÃO D5A.	66
FIGURA 27 - COMPARATIVO ENTRE OS ALGORITMOS DE MODELAGEM DIGITAL, PARA O TALHÃO D5A.	68
FIGURA 28 - DESEMPENHO DA CONTAGEM PARA O FILTRO DE MÁXIMA LOCAL COM JANELA DE DIMENSÃO FIXA.....	69
FIGURA 29 - DESEMPENHO DA CONTAGEM PARA O FILTRO DE MÁXIMA LOCAL COM JANELA DE DIMENSÃO MÓVEL, PROPORCIONAL A ALTURA.....	71
FIGURA 30 - DESEMPENHO DA CONTAGEM PARA O FILTRO DE MÁXIMA LOCAL COM JANELA DE DIMENSÃO MÓVEL, INVERSAMENTE PROPORCIONAL A ALTURA.....	72
FIGURA 31 - DESEMPENHO DA CONTAGEM PARA A SEGMENTAÇÃO POR BACIAS HIDROGRÁFICAS.	73
FIGURA 32 - DESEMPENHO DA CONTAGEM PARA A SEGMENTAÇÃO PELO FILTRO DE MÁXIMOS GLOBAIS.....	74

LISTA DE TABELAS

TABELA 1 - CARACTERÍSTICAS DO SENSOR UTILIZADO.....	38
TABELA 2 – CARACTERÍSTICAS DO LEVANTAMENTO LIDAR.....	39
TABELA 3 - TRATAMENTOS E TIPOS DE DADOS, APÓS O PRÉ- PROCESSAMENTO	50
TABELA 4 - CENÁRIOS ORIUNDOS DAS COMBINAÇÕES ENTRE ALGORITMOS DE IDENTIFICAÇÃO E DADOS DE ENTRADA	55
TABELA 5 – VALORES DE CLASSIFICAÇÃO DE ACORDO COM O ÍNDICE DE DESEMPENHO.....	61
TABELA 6 - CENSO QUANTITATIVO DOS TALHÕES.....	62
TABELA 7 – DENSIDADE E RETORNOS DAS NUVENS DE PONTOS LIDAR, DOS TALHÕES EM ESTUDO	63
TABELA 8 - DENSIDADE DA NUVEM DE PONTOS CLASSIFICADA, POR CLASSE	65
TABELA 9 - ALGORITMO ADERENTE E PARÂMETROS DE AVALIAÇÃO PARA OS TALHÕES DE 10 E 15 ANOS DE IDADE.....	75
TABELA 10 - CENÁRIO COM DESEMPENHO SATISFATÓRIO PARA OS TALHÕES DE 10 E 15 ANOS DE IDADE.....	75
TABELA 11 - ALGORITMOS ADERENTES E PARÂMETROS DE AVALIAÇÃO PARA OS TALHÕES DE 10 ANOS DE IDADE.....	76
TABELA 12 – CLASSIFICAÇÃO DOS CENÁRIOS COM DESEMPENHO SATISFATÓRIO PARA OS TALHÕES COM 10 ANOS DE IDADE ...	76
TABELA 13 - ALGORITMOS ADERENTES E PARÂMETROS DE AVALIAÇÃO PARA OS TALHÕES DE 15 ANOS DE IDADE.....	77
TABELA 14 - CLASSIFICAÇÃO DOS CENÁRIOS COM DESEMPENHO SATISFATÓRIO PARA OS TALHÕES COM 15 ANOS DE IDADE ...	78

LISTA DE ABREVIATURAS E SIGLAS

ALS	- <i>Airborne Laser Scanning</i> (Laser scanner aéreo)
ARP	- Aeronave Remotamente Pilotada
ASPRS	- <i>American Society for Photogrammetry and Remote Sensing</i> (Sociedade Americana de Fotogrametria e Sensoriamento Remoto)
CB	- <i>Contour Based</i> (com base em contornos)
CHM	- <i>Canopy Height Model</i> (Modelo de altura de copa)
csf	- <i>Cloth Simulation Filter</i> (Filtro simulador de tecidos)
DAP	- Diâmetro à altura do peito (1,3 m)
DSMn	- <i>Digital Surface Model normalized</i> (Modelo Digital de Superfície Normalizado)
DTM	- <i>Digital Terrain Model</i> (Modelo Digital de terreno)
Er	- Erro médio relativo
FOV	- <i>Field of vision</i> (Campo de visão)
GNSS	- <i>Global Navigation Satellite System</i> (Sistema de Navegação Global por Satélite)
GPS	- <i>Global Positioning System</i> (Sistema de Posicionamento Global)
IDW	- <i>Inverse Distance Weighted Interpolation</i> (Ponderação pelo Inverso da Distância)
IF	- Inventário Florestal
IFC	- Inventário Florestal Contínuo
IMU	- <i>Inertial Measurement Unit</i> (unidade de mensuração inercial)
INS	- <i>Inertial Navigation System</i> (Sistema de Navegação Inercial)
ITD	- <i>Individual tree detection</i> (Detecção individual de árvores)
k-NN	- <i>k-Nearest Neighbor</i> (número <i>n</i> de vizinhos mais próximos)
LAS	- formato de arquivo para o intercâmbio de dados tridimensionais da nuvem de pontos.
LASER	- <i>Light Amplification by Stimulated Emission of Radiation</i>
LiDAR	- <i>Light Detection and Ranging</i>
LidR	- Biblioteca em R, para manipular dados LiDAR em aplicações florestais

LM	- <i>Local Maximum</i> (Máxima local)
MAPGEO	- Modelo digital da ondulação geoidal
MDA	- Modelo digital de altura
MDE	- Modelo digital de elevação
MDT	- Modelo digital de terreno
NP	- Nuvem de pontos
PITFREE	- Interpolação livre de vales
pmf	- <i>Progressive morphological filter</i> (Filtro morfológico progressivo)
R	- Linguagem de programação R
RF	- <i>Random Forest</i>
RGB	- <i>Red, Green and Blue</i> (Bandas do espectro visível - Vermelho, verde e azul)
RMSE	- Raiz do Erro Quadrático Médio relativo
RPAS	- <i>Remotely Piloted Aircraft Systems</i> (Sistema de Aeronave Remotamente Pilotada)
RTK	- <i>Real Time Kinematic</i> (Posicionamento Cinemático em Tempo Real)
S	- Erro padrão da estimativa relativo
SfM	- <i>Structure from Motion</i>
SIRGAS	- Sistema de Referência Geocêntrico para as Américas
SOR	- <i>Statistical Outlier Removal</i> (Remoção estatística de erros grosseiros)
sp	- Espécie
spp	- Espécies
TIN	- <i>Triangulated irregular network</i> (Rede de Triângulos Irregulares)
TM	- <i>Template Matching</i> (Correspondência de modelos)

SUMÁRIO

1 INTRODUÇÃO	16
1.1 OBJETIVOS	18
1.1.1 Objetivo geral	18
1.1.2 Objetivos específicos.....	18
2 REVISÃO DE LITERATURA	19
2.1 ESTIMATIVAS E CENSO FLORESTAL.....	19
2.2 DETECÇÃO DE ÁRVORES COM DADOS LIDAR	20
2.2.1 Detecção de árvores em povoamentos de <i>Pinus</i> sp.	21
2.3 SISTEMAS LIDAR.....	23
2.3.1 Funcionamento dos sistemas LiDAR	24
2.3.2 Resposta da superfície aos pulsos LiDAR	27
2.3.3 Área atingida pelo pulso em função da distância	28
2.4 ALGORITMOS DE CONTAGEM.....	30
2.4.1 Filtro de máximos locais	30
2.4.2 Segmentação por bacias.....	32
2.4.3 Filtro de máximos globais.....	33
3 MATERIAIS E MÉTODOS	36
3.1 CARACTERIZAÇÃO DA ÁREA.....	36
3.2 CARACTERIZAÇÃO DOS LEVANTAMENTOS	37
3.2.1 Levantamento LiDAR	37
3.2.2 Censo Florestal	40
3.3 PROCESSAMENTO DE DADOS.....	41
3.3.1 Remoção de pontos discrepantes	41
3.3.2 Classificação de nuvens de pontos	42
3.3.2.1 Filtro morfológico progressivo.....	42
3.3.2.2 Filtro simulador de tecidos	44
3.3.3 Normalização de nuvens de pontos	46
3.3.4 Modelagem digital	47
3.3.4.1 Interpolador ponderado inverso da distância.....	47
3.3.4.2 Rede de triângulos irregulares.....	48
3.3.4.3 Rede de triângulos irregulares com restrição	49

3.3.4.4 Rede de triângulos irregulares livre de poços.....	49
3.3.5 Dados tratados	49
3.4 ALGORITMOS DE CONTAGEM AVALIADOS.....	50
3.4.1 Filtro de máxima local.....	50
3.4.1.1 Janela de busca fixa	51
3.4.1.2 Janela de busca móvel em função da altura	51
3.4.2 Segmentação por bacias hidrográficas	53
3.4.3 Filtro de máximos globais.....	53
3.5 EXECUÇÃO DA CONTAGEM.....	54
3.6 AVALIAÇÃO DOS ALGORITMOS	58
4 RESULTADOS.....	62
4.1 CENSO FLORESTAL.....	62
4.2 PROCESSAMENTO DE DADOS LIDAR	62
4.2.1 Qualidade da nuvem LiDAR	62
4.2.2 Classificação e normalização de nuvem de pontos.....	64
4.2.3 Modelo digital de copas e elevação	66
4.3 DETECÇÃO E CONTAGEM DE ÁRVORES.....	69
4.3.1 Filtro de máxima local.....	69
4.3.1.1 Janela de busca fixa	69
4.3.1.2 Janela de busca móvel em função da altura	70
4.3.2 Segmentação por bacias hidrográficas	72
4.3.3 Segmentação pelo filtro de máximos globais	73
4.4 ALGORITMOS ADERENTES.....	74
4.4.1 Talhões com 10 e 15 anos de idade	75
4.4.2 Talhões com 10 anos de idade	76
4.4.3 Talhões com 15 anos de idade	77
5 DISCUSSÃO	79
6 CONCLUSÕES	81
7 RECOMENDAÇÕES PARA TRABALHOS FUTUROS	83
REFERÊNCIAS.....	84
APÊNDICES	92

1 INTRODUÇÃO

O inventário florestal tem importância para atividades de manejo florestal, pois trata-se da única fonte de dados a respeito das características de determinada área e qual irá definir a condução da mesma (PÉLLICO NETTO e BRENA, 1997). Visto as grandes dimensões dos povoamentos florestais, torna-se impraticável a mensuração de todas as árvores para dimensionamento de variáveis relacionadas a produção, sendo comum a utilização de técnicas de amostragem para as estimativas florestais (WEST, 2015).

O emprego do *Light Detection and Ranging* (LiDAR) vem se fazendo presente em estimativas florestais, com destaque na possibilidade recente do uso destes sensores acoplados em Aeronave Remotamente Pilotada (ARP). Silva et al. (2016) indicaram que o LiDAR tem demonstrado um bom potencial para o inventário florestal ao nível de árvores individuais. Dalla Corte et al. (2020) demonstraram a possibilidade de medição direta de diâmetro das árvores com nuvens de alta densidade em povoamentos de *Eucalyptus benthamii*, com espaçamento regular de 2x14 m, proporcionando a modelagem volumétrica individual.

Atualmente poucos métodos automatizados para a contagem de indivíduos arbóreos são utilizados, devido à alta complexidade exigida para o manuseio de tais algoritmos computacionais, demanda computacional ou baixa acurácia obtida nos processamentos, que não atinge as demandas exigidas pelas empresas florestais (SANTOS, 2018).

Conforme apontado por Packalén et al. (2011), para a viabilização da detecção automática de árvores, devem ser analisadas as características: idade, espaçamento e espécie de cada reflorestamento. De acordo com Mohan et al. (2017), um nível aceitável de acerto relacionado ao número de árvores, que deve ser maior que 80%.

Kaartinen et al. (2012) ressaltaram que a detecção de árvores, além de fornecer uma distribuição espacial dos indivíduos do povoamento, reduz a quantidade de trabalho em campo relacionado as estimativas florestais obtidas via inventário florestal.

A detecção automática de árvores com a utilização de dados de sensoriamento remoto, está diretamente relacionada ao uso de tecnologia avançada, e a coleta de informações detalhadas (SANQUETTA et al., 2014). Porém, conforme

Silva et al. (2016a), existe a necessidade de estudos para avaliação da aquisição e processamento de dados LiDAR contra o inventário florestal convencional e respectivos desempenhos entre as metodologias.

A demanda deste trabalho se dá pela não aderência a valores de número de indivíduos por povoamento de *Pinus taeda* L., quando executados algoritmos de identificação em nuvens de pontos LiDAR de baixa densidade, em idades próximas ao corte, visto que as copas acabam entrelaçando-se entre si. Por consequência necessitam do uso de diversos softwares para o tratamento da nuvem de pontos, segmentação e contagem, exigindo uma alta demanda computacional.

Como hipótese, espera-se encontrar por meio de combinações de processamentos, um cenário genérico aplicado a detecção automática de árvores para a espécie *Pinus taeda* L., em povoamentos de 10 e 15 anos de idade, regularmente espaçados. Provendo a redução do esforço amostral tradicional para obtenção de estimativas de produção florestal.

1.1 OBJETIVOS

1.1.1 Objetivo geral

Avaliar diferentes cenários, para a contagem automática de árvores, em povoamentos florestais regularmente espaçados, utilizando dados LiDAR aerotransportado de baixa densidade, visando subsidiar os inventários florestais na mensuração da variável: número de árvores.

1.1.2 Objetivos específicos

Baseado no objetivo geral deste trabalho, os objetivos específicos são os que seguem:

- Testar algoritmos de identificação e contagem de árvores já implementados, que demandem de interferência mínima do usuário;
- Analisar a acurácia dos cenários testados quando comparados ao censo do povoamento e indicar o de melhor desempenho.

2 REVISÃO DE LITERATURA

2.1 ESTIMATIVAS E CENSO FLORESTAL

Os recursos demandados em povoamentos florestais dependem de informações de produtividade do talhão, sendo esta produtividade definida por meio do inventário florestal, em que povoamentos são amostrados de forma representativa, por meio de uma boa intensidade amostral, o que possibilita estimar o volume e outras variáveis com a precisão desejada e custo que viabilize a produção (SCOLFORO; MELLO, 2006).

Também se utiliza o inventário florestal para se estimar o número total de árvores de um plantio (MELLO et al., 2009), mesmo em povoamentos plantados o número de árvores não é conhecido com exatidão. Estimando-se o volume do povoamento extrapolando o volume total de madeira das parcelas para a área de plantio (OLIVEIRA, 2014).

O Inventário Florestal Contínuo (IFC), é uma das formas de inventário mais utilizadas para acompanhar o crescimento da floresta. Tem-se observado que alguns erros, tais como na mensuração de diâmetros, de alturas e de área das parcelas, erro na manipulação dos dados, e erros associados ao procedimento de amostragem, que variam em relação à variável dendrométrica analisada, sendo maior para a variável “número de árvores por hectare” (OLIVEIRA, 2014).

Esses erros levam à diminuição da qualidade dos dados obtidos, refletindo na imprecisão dos modelos de crescimento e produção e, conseqüentemente, no planejamento, e só podem ser resolvidos se for realizado o censo na área. (OLIVEIRA, 2014).

Se conhecido o número de árvores dos povoamentos, o volume médio das árvores das parcelas poderia ser extrapolado pelo número total de árvores. Isso diminuiria o erro do inventário e poderia reduzir a intensidade amostral necessária para o pré-corte, etapa onerosa e indispensável nos meses anteriores à colheita (OLIVEIRA, 2014).

Os inventários por censo, devido ao seu alto custo e o tempo necessário à sua realização, só se justificam nas avaliações de populações pequenas, de grande importância econômica (PÉLLICO NETTO e BRENA, 1997). O emprego de dados

LiDAR, visa atenuar as dificuldades encontradas até então para a execução de censos florestais.

2.2 DETECÇÃO DE ÁRVORES COM DADOS LIDAR

Levantamentos LiDAR têm sido empregados em muitas aplicações, tais elas como: mapeamento topográfico, obras de engenharia, monitoramento de redes elétricas e no meio florestal para a determinação da altura das árvores, caracterização de dossel, área de copa, contagem de plantas, determinação de volume e biomassa (MACEDO, 2009).

Por sua agilidade de coleta de dados precisos os sistemas LiDAR têm sido utilizados para avaliações rápidas de danos causados por desastres naturais tais como terremotos, furacões, inundações, e para planejamento efetivo de emergências (MACHADO, 2006).

Desenvolvidos inicialmente para levantamento de dados para elaboração de modelos digitais de terreno (DTM – *Digital Terrain Model*), sobretudo para locais de difícil acesso, os sistemas ALS, têm se destacado entre as técnicas de sensoriamento remoto, apresentando bons resultados na área florestal (LARANJA, 2016).

Na área florestal, o LiDAR possibilita o correto posicionamento da superfície do solo e dos elementos da vegetação, devido ao sistema de posicionamento e a diferenciação dos retornos (RODRIGUEZ et al., 2010; VASTARANTA, 2012). A possibilidade de obtenção de medidas da altura da vegetação e do solo viabiliza o uso de informações provenientes do ALS (LINDBERG, 2012), essa tecnologia permite a obtenção de variáveis dendrométricas de forma direta ou através de modelagem (GIONGO et al., 2010).

O LiDAR viabiliza gerar um modelo de altura de copa (CHM – *Canopy Height Model*) que pode ser usado para a detecção individual de árvores, o delineamento de copas de árvores e subsequentemente a estimativa de atributos biométricos, como biomassa e volume (SILVA, 2017).

A tecnologia ALS teve seu uso inicial aplicado à medição de alturas. Na década de 1980, para estimar alturas, diâmetro de copa e densidade de cobertura vegetal, e a determinação do terreno abaixo da vegetação (MARTINS, 2016).

As pesquisas com dados LiDAR possibilitam a determinação da altura das árvores, variáveis dendrométricas, biomassa entre outros mediante o uso de modelos

de regressão em que as variáveis independentes são a altura das árvores e/ou diâmetro de copa (FRIEDLAENDER e KOCH, 2000).

No emprego do ALS considera-se atualmente duas abordagens para caracterização dos recursos florestais: uma em nível de área (ABA – *Area-Based Approach*) e outra para a identificação de árvores individuais (ITD – *Individual Tree Detection*) (LARANJA, 2016).

2.2.1 Detecção de árvores em povoamentos de *Pinus* sp.

A frequência de estudos em povoamentos de *Pinus* sp. se apresentaram menos constante, quando comparada a estudos relacionados a outras espécies, assim como os algoritmos utilizados não seguem uma metodologia padrão, são testadas diversas alternativas, conforme apresentados nos estudos a seguir.

Zandoná et al. (2008), analisando um plantio de 40 anos de idade de *Pinus taeda* L., implementaram um algoritmo de máximas locais para a individualização das árvores, em um CHM proveniente de dados LiDAR e um filtro para suavização, e delimitaram as copas utilizando as partes mais altas das árvores por meio de um algoritmo de crescimento de regiões. Foram identificadas corretamente 82,8% das árvores.

Straub e Koch (2011) identificaram manualmente a coroa e o ápice das copas de parcelas instaladas em povoamento de *Pinus sylvestris*, utilizando dados LiDAR aerotransportado e sensores multiespectrais, para estimativas de volume de tronco com base na altura das árvores e diâmetro de copas.

Kathuria et al. (2016) desenvolveram um algoritmo de identificação de árvores baseado em máximos locais com raio de busca dinâmico em função da vizinhança dos pontos LiDAR aerotransportado, para a espécie *Pinus radiata*, estimando o número de árvores com um erro médio quadrático de 5,7%, em dados de baixa densidade (2 pontos/m²), porém, computacionalmente exigente.

Silva et al. (2016) fizeram uso de classificador RF k-NN (*Random Forest* e *k-Nearest Neighbor*) para detecção individual de árvores em povoamento de *Pinus palustres* Mill, baseado no modelo de copas proveniente de dados LiDAR aerotransportado, atingindo alta precisão chegando a 96% de acurácia em florestas com cobertura de dossel menor que 70%.

Chen e Zhu (2013) integraram uma plataforma de sistema de informação geográfica ao tratamento de dados LiDAR, na qual, faz uso de segmentação de bacias hidrográficas controlada por marcador, com testes em povoamentos de *Pinus radiata*, denso e não desbastado, atingindo precisão de 1,87m na posição das árvores identificadas.

Kaartinen et al. (2012) realizaram um estudo em povoamentos de *Pinus sylvestris*, *Picea abies* e *Betula* sp. levantamento ALS com densidade de pontos de 2, 4 e 8 pontos por m². Dentre todos os testes aplicados, o algoritmo de máximo local foi uma das melhores técnicas aplicadas ao estudo, atingindo 102% para a estimativa do número de indivíduos dominantes.

Hentz et al. (2018) utilizaram ARP na coleta de dados com sensor passivo com a finalidade de gerar nuvens de pontos tridimensionais, por correlação fotogramétrica em florestas de *Eucalyptus* spp. e *Pinus taeda* L. com idade de 1,5 anos, para posterior individualização baseada em segmentação de bacias hidrográficas e máximos locais atingindo um erro máximo de 6%.

Jaakkola et al. (2017) também utilizaram um ARP na coleta de dados, porém, com um sensor ativo de baixo custo embarcado, atingindo uma taxa de detecção de 100% em árvores isoladas e dominantes, mostrando a viabilidade para o uso de ARP e sensores de baixo custo para as características específicas da floresta estudada, que consiste em uma floresta boreal manejada de idade não determinada onde as principais espécies dominantes são *Pinus sylvestris* e *Picea abies*.

Panagiotidis et al. (2017) utilizaram imagens tomadas por ARP para reconstrução da superfície de dossel florestal aplicando a técnica de reconstrução *Structure for motion* (SfM), em talhões de diferentes idades de *Picea abies* L., *Larix decidua* Mill., *Pinus sylvestris* L. e *Betula pendula* Roth, para a obtenção da altura aplicou o algoritmo de máximas locais e para delimitação das copas a segmentação inversa de bacias hidrográficas.

Para povoamentos de *Pinus* sp. não existe um domínio de apenas um algoritmo de detecção automática de árvores, pois, são utilizados diferentes algoritmos, assim como, diferentes pré-processamentos no tratamento das nuvens de pontos LiDAR. Muitos estudos para *Pinus* sp. não atingiram níveis satisfatórios de detecção de árvores.

2.3 SISTEMAS LIDAR

A ideia originária do LASER emergiu por volta de 1905, quando Albert Einstein sugeriu as emissões de luz estimuladas (MACHADO, 2006). Schawlow e Townes (1958), pela primeira vez, estabeleceram a teoria para obter a amplificação de luz por emissão estimulada de radiação (laser) com base nos fundamentos estabelecidos por Einstein.

Nas décadas de 1960 e 1970, várias experiências demonstraram o poder de utilização do laser em sensoriamento remoto, incluindo diversas aplicações, como monitoramento atmosférico e estudos oceanográficos (Wehr e Lohr, 1999).

De acordo Dresch e Santos (2015) o LiDAR (*Light Detection and Ranging*) é um sistema de sensoriamento remoto ativo capaz de determinar coordenadas tridimensionais de pontos sobre a superfície terrestre de forma rápida, precisa e segura por meio da geração, emissão e captura de pulsos LASER (*Light Amplification by Stimulated Emission of Radiation*) que podem operar tanto na faixa do espectro eletromagnético do visível até o infravermelho médio (FERRAZ, 2016), integrados com dados do sistema de posicionamento GNSS (*Global Navigation Satellite System*) e do sistema de navegação IMU (*Inertial Measurement Unit*) registrando o tempo de emissão e recepção do pulso, as informações fornecidas pelos sistemas de integração GNSS/IMU e a intensidade de retorno do pulso, estabelecem nuvens de pontos georreferenciadas (PAVAN, 2011).

Apesar de o laser não ser uma nova tecnologia, sua utilização na aquisição de dados geográficos é relativamente recente. Seu uso em sistemas LiDAR (*Light Detection and Ranging*) vem demonstrando uma excelente capacidade para a aquisição de uma grande quantidade de informações, em pequeno intervalo de tempo. (GIONCO et. al., 2010).

O LiDAR tem sido considerado uma técnica rápida, segura e precisa de aquisição de informações tridimensionais sobre a superfície física. A acessibilidade, o aumento na densidade e versatilidade de novos sistemas LiDAR tem causado exponencial profusão e disponibilidade dos dados derivados do sistema (PAVAN, 2011).

Uma das vantagens do LiDAR é o seu uso na integração dos dados derivados dos diferentes sensores como alternativa para extração de apoio de campo de forma rápida, autônoma e direta (PAVAN, 2011).

Pavan (2011), ainda destaca outras vantagens do LiDAR, tais como a alta densidade de informações sobre superfícies homogêneas, por se tratar de um sensor ativo, a aquisição direta de informações tridimensionais e a precisão altimétrica melhor que a planimétrica.

2.3.1 Funcionamento dos sistemas LiDAR

Os sistemas LiDAR, funcionam com um conjunto ótico de lentes e espelhos orienta os pulsos laser, gerados pelo gerador de pulsos, emitindo-os para os objetos no terreno e sequencialmente recebendo os sinais de retorno e direcionando-os para o receptor (GIONGO, 2010).

A quantidade de pontos obtidos por unidade de área (densidade) varia em função de algumas configurações do sistema e do voo, como: ângulo de abertura, diâmetro do feixe, frequência de varredura, velocidade da aeronave e altura de voo (LARANJA, 2016).

A varredura LiDAR é feita no sentido transversal à direção da linha de voo, com a abertura configurável pelo sistema, formando a largura da faixa abrangida. O movimento da aeronave permite a cobertura na direção da linha de voo (MACEDO, 2009). Qual pode ser definido pela equação a seguir, e exemplificado na Figura 1.

$$L = 2 \cdot h \cdot \tan\left(\frac{\theta}{2}\right) \quad (1)$$


Em que:

L = largura de faixa;

h = altura de voo;

θ = ângulo de varredura (em radianos).

FIGURA 1 - ELEMENTOS DETERMINANTES DA LARGURA DA FAIXA.



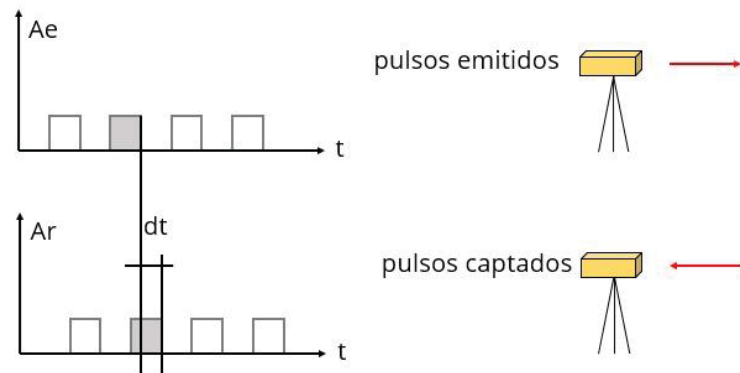
FONTE: Adaptado de Macedo (2009).

O ângulo de varredura é um parâmetro configurável, ângulos menores são utilizados para aplicações específicas, tais como levantamentos de detecção de cabos de linha de transmissão e para melhor penetração na vegetação. A densidade de pontos é dependente da velocidade de voo e da potência do equipamento (MACEDO, 2009).

O sistema possui sua própria fonte de energia e pode ser operado em ondas contínuas (*full-waveform*), onde o sistema utiliza a fase para medir a diferença entre emissão e detecção, ou modo de pulso discreto (*discrete echo*), que utiliza o tempo para medir a diferença entre emissão e detecção. Como a velocidade da luz é conhecida, a distância é calculada através da diferença de tempo entre a emissão e o retorno (MACEDO, 2009).

Os sistemas LiDAR de pulsos discretos (Figura 2), registra o intervalo para o primeiro ou o último retorno dos pulsos e alguns registram o retorno dos pulsos intermediários (GIONCO et. al., 2010).


FIGURA 2 - SISTEMA COM RETORNOS DISCRETOS.



FONTE: Adaptado de Centeno (2003).

Já os sistemas LiDAR de ondas contínuas (Figura 3), possibilitam registrar integralmente todo o sinal do pulso (GIONCO et. al., 2010).

FIGURA 3 - SISTEMA DE ONDAS COMPLETAS.



FONTE: Adaptado de Centeno (2003).

A velocidade de propagação é uma das propriedades fundamentais da luz. Num determinado meio, a luz viaja com uma velocidade finita e constante (DRESCH, 2015). No modo de pulso, as coordenadas dos pontos que compõe a nuvem de pontos LiDAR são definidas em função da distância, que é calculada pela equação a seguir:

$$D = c \cdot \left(\frac{dt}{2} \right) \quad (2)$$

Em que:

D = distância;

c = velocidade de propagação da luz no vácuo;

dt = tempo entre a emissão e recepção de um pulso.

A frequência do raio LASER se situa na faixa de 500 a 1500nm, com valores típicos de 1040 a 1060nm. Estas frequências são refletidas pelo terreno, vegetações e pelas nuvens, de forma que não se pode operar com nuvens se interpondo entre a aeronave e o terreno. Entretanto ele não sofre com a falta de iluminação ou com sombras possibilitando utilizá-lo durante qualquer parte do dia e em qualquer estação (MACHADO, 2006).

2.3.2 Resposta da superfície aos pulsos LiDAR

Um LiDAR emite sua própria potência em um ângulo pequeno e ilumina uma porção da superfície física, que resultará em diferentes medidas de intensidade, devendo esta intensidade ser normalizada para uma distância conhecida para a possibilidade de comparações. Em uma superfície homogênea, a intensidade refletida é proporcional à potência emitida, dividida pela área iluminada e multiplicada pela refletividade desta superfície (MACEDO, 2009).

$$I_m = \frac{P_e}{S^2} \cdot r \quad (3)$$

Em que:

I_m = intensidade refletida;

P = potência emitida;

S = distância;

r = refletividade da superfície.

De acordo com Macedo (2009), existem diferenças de intensidade de uma mesma região espectral, pontos de terreno assumem valores altos de intensidade, já pontos de copas possuem valores intermediários. As razões para que a intensidade

proveniente de vegetais tenha valores menores que a intensidade proveniente do terreno, são:

- As folhas individualmente retroespalham uma grande proporção de radiação, elas estão dispostas de maneira difusa e desorganizada, reduzindo drasticamente a proporção que retorna ao sensor;
- A mensuração de energia é de apenas uma porção do dossel, podendo amostrar troncos, galhos, entre outros;
- O espalhamento múltiplo é menor, por ser uma pequena superfície iluminada;
- Apesar de a refletância do terreno ser menor que a vegetação, a projeção de iluminação pode gerar alto retorno.

As múltiplas reflexões de um raio chegam ao receptor em tempos diferentes, de forma que elas podem ser discriminadas, se a vegetação não for muito densa, de 20% a 50% dos raios LASER atingem o solo (MACHADO, 2006).

2.3.3 Área atingida pelo pulso em função da distância

O feixe LASER possui um pequeno ângulo de divergência, tornando sua projeção na superfície não pontual, mas forma uma superfície circular ou elíptica, esta superfície é denominada como *footprint* (MACEDO, 2009), apresentado na Figura 4 e calculado de acordo com a equação a seguir:

$$F = 2 \cdot h \cdot \tan\left(\frac{\gamma}{2}\right) \quad (4)$$


Em que:

F = *footprint*;

h = altura de voo;

γ = ângulo de divergência do pulso, em radianos.

FIGURA 4 - ELEMENTOS DETERMINANTES DO FOOTPRINT




FONTE: Adaptado de Reutebuch; Andersen e McGaughey (2005) e Silva (2014).

A largura do feixe pode ser classificada como *small footprint* quando o diâmetro do raio LASER projetado é inferior a um metro, ou *large footprint* quando o diâmetro é maior que um metro, uma característica importante do *footprint* é a detecção de mais de um alvo simultaneamente em um mesmo feixe, originando retornos distintos (MARTINS, 2016).

Em aplicações florestais, normalmente, são utilizados *small footprint*, por possibilitar boas correspondências entre os dados LiDAR e árvores individuais, parcelas, ou povoamentos florestais (LARANJA, 2016).

O diâmetro do feixe terá um efeito muito importante em aplicações florestais, múltiplas reflexões acontecem quando, o raio atinge uma árvore e uma parte do mesmo é refletida pelas folhas e outra parte é refletida pelo chão, constituindo uma poderosa ferramenta, para a determinação da altura da vegetação existente em uma região (MACHADO, 2006). A Figura 5 exemplifica o comportamento do retorno do sinal.

FIGURA 5 - COMPORTAMENTO DO RETORNO DO SINAL.



FONTE: Adaptado de Reutebuch; Andersen e McGaughey (2005) e Silva (2014).

2.4 ALGORITMOS DE CONTAGEM

A detecção automática de indivíduos é de fundamental importância na área florestal, uma vez que possibilita a obtenção de variáveis biométricas, mostrando-se uma técnica que subsidia a execução de inventários florestais, tornando-o cada vez mais eficiente, uma vez que esta é uma etapa onerosa e que demanda tempo (SILVA et al., 2017).

2.4.1 Filtro de máximos locais


O filtro de máximo local, utiliza o modelo digital de alturas, modelo digital de elevação ou a nuvem de pontos para identificar os máximos locais no interior de uma janela de busca de tamanho variável ou fixo que percorre toda a imagem correspondente ao dossel florestal (McGAUGHEY, 2014).

O desempenho do algoritmo depende do conhecimento do tamanho de copa das árvores, espaçamento de plantio, altura das árvores ou por testes de tamanhos de janelas de busca e avaliação do resultado final (SANTOS, 2018).

As janelas podem apresentar-se no formato quadrado ou circular com dimensões fixas ou em função do valor do pixel, que no caso representa a altura da árvore.

O funcionamento parte do princípio de que nos modelos digitais, os ápices das árvores possuem maiores valores de refletância em níveis de cinza que os pixels presentes em seu entorno (SANTOS, 2018). Portanto adota-se que os valores mais elevados em uma vizinhança espacial representam a ponta da copa da árvore (LARANJA, 2016). Conforme apresentado na Figura 6.

FIGURA 6 – IDENTIFICAÇÃO DO MÁXIMO LOCAL



FONTE: Adaptado de Popescu e Wynne (2004).

Quando um pixel é selecionado como uma máxima local e os pixels adjacentes são verificados se possuem valores inferiores. A partir dos pontos de máximas locais são geradas regiões estendidas, à medida que pixels adjacentes com valores inferiores forem captados (OLIVEIRA, 2011). Este se confirmado como o ponto de maior refletância e consequentemente de maior altura é classificado como o ápice de uma árvore (WULDER; NIEMANN; GOODENOUGH, 2000).

2.4.2 Segmentação por bacias


A segmentação é um processo onde a imagem é particionada em regiões que devem corresponder às áreas de interesse da aplicação. A segmentação por bacias considera a característica espacial dos dados e garante a formação de segmentos fechados (RIBAS, 2013).

O método simula uma imersão em água em um modelo digital em escala de cinza, os pixels provenientes de diferentes pontos mínimos se fundem formando uma barragem que corresponde à bacia hidrográfica, possibilitando a delimitação das bordas e topo das árvores (MILLIKAN et. al., 2019).

Basicamente a segmentação ocorre com base em uma superfície topográfica com inserção de uma fonte de água a iniciar do ponto mínimo do relevo, toda a superfície é inundada até o ponto mais alto, em locais onde diferentes fontes de água se encontram são criadas barreiras, estas quais delimitam as bacias hidrográficas (HUANG et. al. 2018).

A figura 7, representa a inundação atuando em um perfil topográfico, e a definição de barreiras de acordo com o incremento do nível de água.

FIGURA 7 - PROCESSO DE INUNDAÇÃO EM UM PERFIL TOPOGRÁFICO



FONTE: Adaptado de Legland et al. (1990) e Soille et al. (1990).

Em geral, a aplicação de segmentação por bacias hidrográficas tende a superestimar ou subestimar o número de árvores em função de suas características, situação que pode ser controlada por marcadores correspondentes ao topo das árvores a serem segmentadas (KWAK et. al., 2007).

A segmentação excessiva é comum em imagens ruidosas, quais são compostas de grande número de mínimos regionais, nestes casos são indicados pré-processamentos de suavização de imagem (LEGLAND et al., 2016).

2.4.3 Filtro de máximos globais

O filtro de máximos globais, propõe um agrupamento de regiões baseado no conceito de região vizinha similar. A cada iteração do algoritmo o par mais semelhante de regiões espacialmente adjacentes é agrupado. Inicialmente um elemento semente pertencente à região a ser segmentada será fornecido e a partir deste se iniciará o processo de agrupamento (RIBAS, 2013).


O filtro de máximos globais é aplicado diretamente em nuvens de pontos 3D. (WALLACE; LUCIEER; WATSON, 2014). O ponto mais alto da nuvem de pontos é classificado como o ápice da primeira árvore, os demais serão classificados conforme os limiares definidos previamente (LI et al., 2012; WALLACE; LUCIEER; WATSON, 2014).

Os limiares, consistem em distancias esperadas entre os ápices e as bases das arvores, distancias estas projetadas no plano, a árvore classificada é separada da nuvem e o processo de busca do ponto mais alto reinicia (SANTOS, 2018).

O método trabalha segmentando árvores individualmente em sequência da mais alta para a mais baixa, a partir da nuvem de pontos com informações tridimensionais, analisando o espaçamento relativo entre as árvores do povoamento florestal.

A Figura 8 apresenta dois possíveis cenários, normalmente existe um espaçamento horizontal entre os ápices das árvores e a borda de suas copas, a distância entre os ápices é maior que a distância entre as bordas das copas, que é o caso do cenário (a). Mesmo que as bordas das copas sejam entrelaçadas a condição de espaçamento entre os ápices é ocorrente, apresentado no cenário (b).


FIGURA 8 - CONDIÇÃO DE ESPAÇAMENTO



FONTE: Adaptado de Li et al. (2012).

A partir da identificação do ápice da primeira árvore, qual coincidente com o ponto mais alto da nuvem de pontos. Pontos com espaçamento maior que um limite pré-definido, são excluídos da árvore alvo, os pontos com espaçamento menor que o limite, são classificados com base em uma regra de espaçamento mínimo entre os pontos vizinhos, conforme apresentado na Figura 9.

FIGURA 9 - REGRA DE ESPAÇAMENTO MÍNIMO



FONTE: Adaptado de Li et al. (2012).

O ponto A é o mais alto e, portanto, é considerado o topo da árvore nº 1. A partir do ponto inicial A, o algoritmo classifica os pontos inferiores sequencialmente, o

ponto B é classificado como árvore pertencente a árvore nº 2 porque o espaçamento d_{AB} é maior que o limite especificado.

O ponto C é o próximo ponto testado, cujo espaçamento d_{AC} é menor que o limite, comparando os pontos A e B, o ponto C é classificado como pertencente a árvore nº 1 porque o d_{AC} é menor que o d_{BC} . Seguindo a mesma lógica o ponto D é classificado como pertencente a árvore nº 2.

O ponto E é classificado como pertencente a árvore nº 2, o parâmetro para essa decisão foram as distancias observadas aos pontos C e D, onde d_{DE} é menor.

O algoritmo segmenta uma árvore a cada iteração, os pontos segmentados são separados da nuvem de pontos não segmentada, o processo é interrompido quando toda a nuvem de pontos estiver segmentada.

Os resultados são sensíveis à escolha dos limiares de área, sendo este o valor de área mínima para que uma região seja individualizada e de similaridade, valor abaixo do qual duas regiões são consideradas similares. Baixos limiares tendem a produzir resultados com grande número de regiões fragmentadas e em contrapartida, altos valores forçam a união de regiões distintas, gerando regiões aglutinadas (ESPINDOLA, 2006).

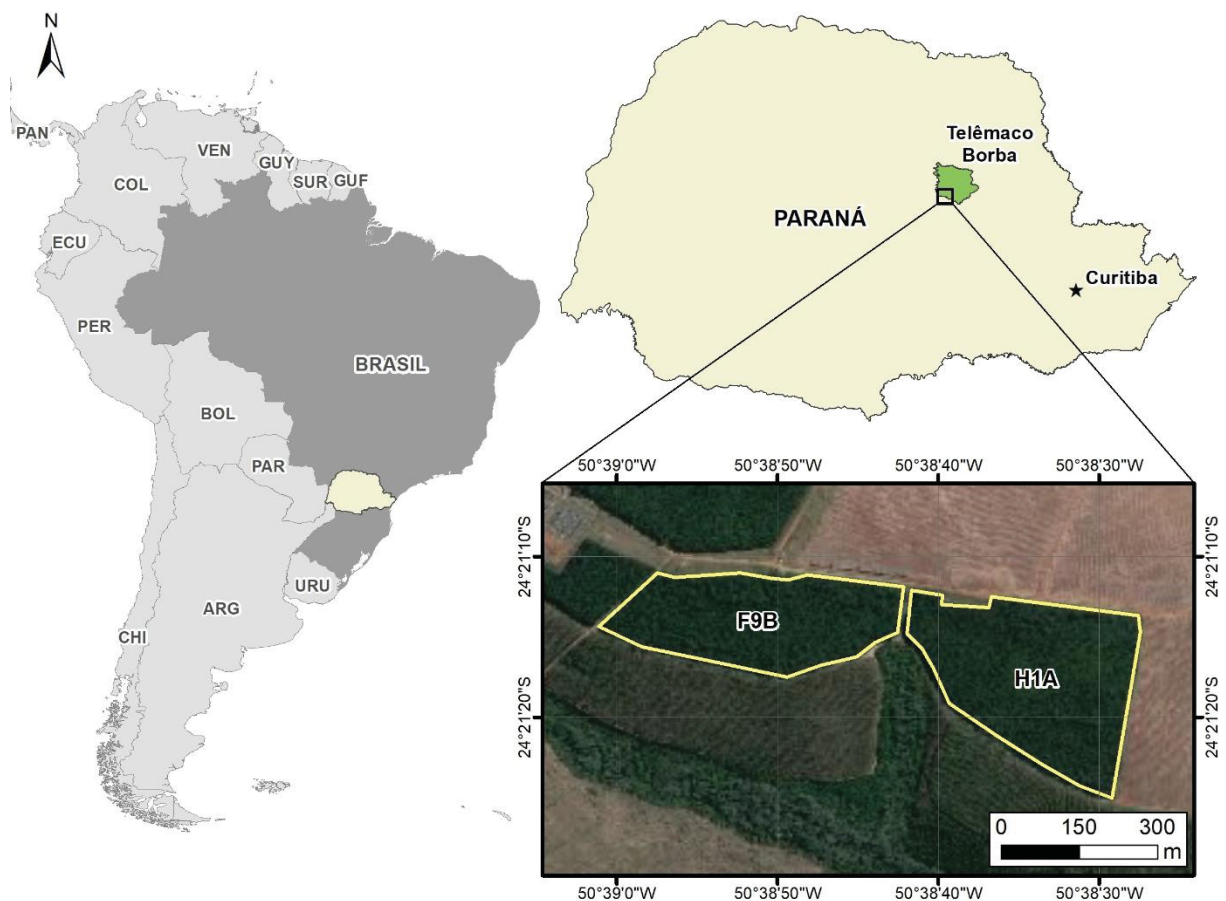
3 MATERIAIS E MÉTODOS

3.1 CARACTERIZAÇÃO DA ÁREA

O trabalho foi realizado em povoamentos clonais de *Pinus taeda* L. em duas fases distintas de desenvolvimento, especificamente em 5 talhões com espaçamento de 2,5 m entre árvores, três com 15 anos e os demais com 10 anos, localizados no município de Telêmaco Borba - PR e pertencentes à empresa Klabin.

Na Figura 10, são apresentados os talhões com 10 anos de idade, F9B com 7,18 hectares e H1A com 9,86 hectares, totalizando 17,04 hectares.

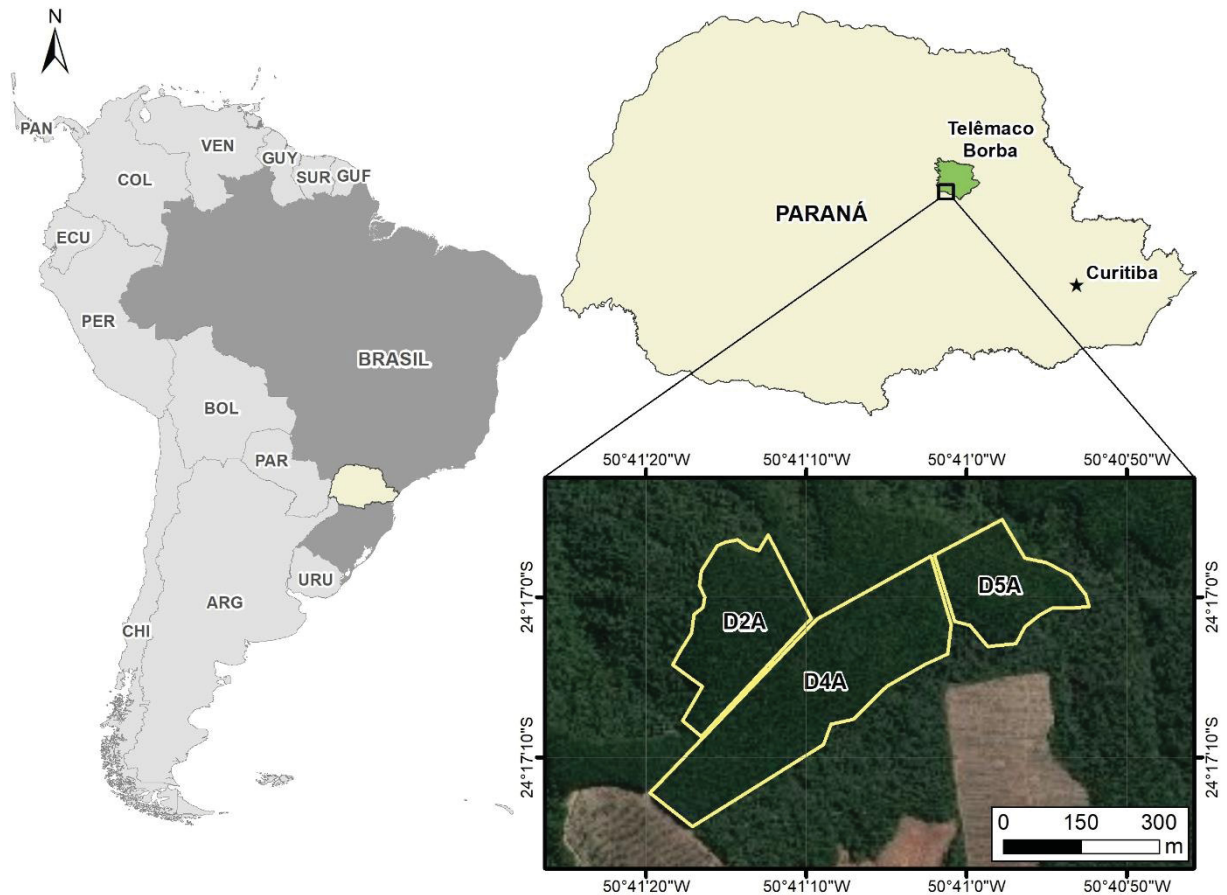
FIGURA 10 - LOCALIZAÇÃO DOS TALHÕES COM 10 ANOS DE IDADE.



FONTE: O Autor (2020).

Na Figura 11, é apresentada a localização dos talhões com 15 anos de idade, com respectivas denominações e área plantada, D2A com 5,11 hectares, D4A com 9,52 hectares e D5A com 3,55 hectares, totalizando 18,18 hectares plantados.

FIGURA 11 - LOCALIZAÇÃO DOS TALHÕES COM 15 ANOS DE IDADE.



FONTE: O Autor (2020).

3.2 CARACTERIZAÇÃO DOS LEVANTAMENTOS

3.2.1 Levantamento LiDAR

O levantamento LiDAR foi executado pela empresa Fototerra, qual utilizou um sensor LiDAR Harrier 68i da Trimble, um sistema inercial e um sistema de posicionamento global de alta precisão, ambos embarcados em uma aeronave CESSNA modelo 206. Apresentado na Figura 12.

FIGURA 12 - CONJUNTO DE EQUIPAMENTOS UTILIZADOS NO LEVANTAMENTO LIDAR



FONTE: Adaptado de FOTOTERRA (2018).

O sistema de referência adotado foi o SIRGAS 2000, com referencial altimétrico ao Datum vertical de Imbituba, obtido por redução da ondulação geoidal por meio do MAPGEO 2015 do IBGE.

O sistema LiDAR Harrier 68i foi configurado para coletar 5 pontos/m² em função dos parâmetros de voo (frequência de operação, FOV, velocidade de cruzeiro e altura de voo). As principais características do sensor LiDAR Harrier 68i são apresentados na tabela 1.

TABELA 1 - CARACTERÍSTICAS DO SENSOR UTILIZADO

Descrição	Unidades
Frequência de varredura	80 kHz - 400 kHz
FOV	45º - 60º
Divergência do feixe	≤ 0.5 mrad
Intensidade do sinal	16 bits
Acurácia Vertical	0,15 m (absoluta)
Acurácia Horizontal	0,25 m (absoluta)

FONTE: Adaptado de FOTOTERRA (2018).

Vista as características do sensor, o plano de voo foi executado conforme a Tabela 2, que apresenta um resumo das características do levantamento.

TABELA 2 – CARACTERÍSTICAS DO LEVANTAMENTO LIDAR

Descrição	Unidades
Altura de voo	666 m
FOV	60º
Footprint	5 mm
Sobreposição lateral	30%
Densidade esperada	5 pontos/m ²


FONTE: Adaptado de FOTOTERRA (2018).

O levantamento LiDAR aerotransportado resultou em nuvens de pontos contínuas, para os processamentos foram considerados apenas os pontos LiDAR no interior do perímetro dos talhões de interesse, os demais foram descartados.

A Figura 13 apresenta as nuvens de pontos LiDAR para os talhões F9B e H1A, de 10 anos de idade, que possuem árvores isoladas acima do dossel de interesse (por exemplo árvores nativas remanescentes), situação que pode ser observada no detalhe, indicando indivíduos de espécies não identificada distintas da espécie de interesse e com altura maior que as árvores plantadas.

FIGURA 13 - NUVENS DE PONTOS LiDAR DOS TALHÕES COM 10 ANOS DE IDADE

Perspectiva




FONTE: O Autor (2020).

A Figura 14 apresenta as nuvens de pontos dos talhões D2A, D4A e D5A, ambos com 15 anos de idade. Nestas nuvens não percebe-se a ocorrência de árvores acima do dossel do plantio florestal. No detalhe circular da Figura 26, pode-se

observar a homogeneidade, onde o primeiro retorno do sinal condiz aos elementos da copa (folhas, galhos e troncos) das árvores que compõe o dossel de interesse.

FIGURA 14 - NUVENS DE PONTOS LIDAR DOS TALHÕES COM 15 ANOS DE IDADE

Perspectiva




FONTE: O Autor (2020).

3.2.2 Censo Florestal

Os cinco talhões em estudo, foram submetidos a contagem de indivíduos ao nível de censo. Após a identificação *in loco* dos talhões, definiu-se a linha de início para a contagem das árvores. Árvores mortas não foram contabilizadas e bifurcadas contabilizou-se o número total de fustes. Para tal fez-se uso de contadores manuais e planilhas impressas para a anotação. A contagem foi organizada por talhão e subdividido por linha de plantio, as quais foram compiladas e somadas para obtenção do número total de árvores. A Figura 15 exemplifica a execução da contagem das árvores em campo.

FIGURA 15 - EXECUÇÃO DO CENSO FLORESTAL.



FONTE: O Autor (2020).

3.3 PROCESSAMENTO DE DADOS

3.3.1 Remoção de pontos discrepantes

As varreduras LiDAR geralmente geram conjuntos de pontos com densidades de pontos variáveis, erros de medição levam a valores discrepantes esparsos, que podem comprometer os resultados (Girardeau-Montaut, 2005).

A remoção dos erros grosseiros é viabilizada na aplicação do filtro SOR (*Statistical Outlier Removal*), onde são calculadas distancias médias entre um ponto e seus vizinhos, classificados como outliers e eliminados os pontos acima da distância média mais um número de vezes o desvio padrão do conjunto amostrado, na qual espera-se uma distribuição normal. Os parâmetros relacionados ao número de vizinhos e o escalar qual multiplicará o desvio padrão são definidos pelo usuário (Chen et. al, 2018).

Os pontos classificados como erros grosseiros, também conhecidos por *outliers*, seguem a condição a seguir.

$$p_i \text{ é outlier se: } x_{pi} > \frac{\sum x_i}{n} + \alpha * \sqrt{\frac{\sum (x_i - \bar{x})^2}{n-1}} \quad (5)$$

Em que:

p_i = ponto testado

x_{pi} = distância do ponto testado ao vizinho mais próximo na amostra;

x_i = distância i pertencente a amostra;

\bar{x} = distância média entre os pontos da amostra

α = escalar de multiplicação

n = tamanho da amostra

3.3.2 Classificação de nuvens de pontos

Classificar nuvens de pontos em medições de solo e não-solo é uma etapa essencial para gerar modelos digitais de terreno. Alguns algoritmos precisam configurar vários parâmetros, com o devido cuidado para obter alta precisão (ZHANG et al., 2016).

3.3.2.1 Filtro morfológico progressivo

O filtro morfológico, consiste na aproximação da superfície do terreno com o emprego de operações de abertura e fechamento (dilatação e erosão), conceitualmente é simples e de fácil implementação (Zhang et al., 2003).

O funcionamento consiste em evoluir gradualmente a janela do elemento estruturante que reflete no maior elemento não pertencente ao solo, com base em uma cota mínima, os pontos que atingem as condições de distância e inclinação indicadas inicialmente pelo usuário são classificados como pontos pertencentes ao solo (MENDONÇA, 2017).

A morfologia matemática compõe operações baseadas em duas operações fundamentais, dilatação e erosão, quando aplicada em um conjunto de pontos tridimensionais, a dilatação retorna o valor máximo de elevação entre os vizinhos de uma determinada área de interesse, já a erosão retorna o valor mínimo da vizinhança, definidos por:

$$d_p = \max_{(x_p, y_p) \in \omega} (Z_p) \quad (6)$$

$$e_p = \min_{(x_p, y_p) \in \omega} (Z_p) \quad (7)$$

Em que:

d_p = Operação de dilatação;

e_p = Operação de erosão;


x_p, y_p, Z_p = coordenadas dos pontos vizinhos;

ω = janela de busca.

A combinação de erosão e dilatação gera operações de abertura e fechamento que são empregadas para filtrar dados do LIDAR.

A operação de abertura é realizada executando uma erosão seguido de uma dilatação, qual realiza a quebra de istmos, elimina cabos e ilhas (INPE, 2006). Como observado na Figura 16.


FIGURA 16 - OPERAÇÃO DE ABERTURA



FONTE: Adaptado de INPE (2006). Em que: A = Imagem original, B = Erosão e C = Dilatação.

Enquanto a operação de fechamento é realizada pela execução uma dilatação seguida de uma erosão, qual elimina golfos e fecha baías (INPE, 2006). Conforme a Figura 17.

FIGURA 17 - OPERAÇÃO DE FECHAMENTO



FONTE: Adaptado de INPE (2006). Em que: A = Imagem original, B = Dilatação e C = Erosão.

A classificação dos pontos do terreno, ocorre devido a simplificação da nuvem após a combinação das operações, que é aplicada em toda a nuvem de pontos, por meio de uma janela de pesquisa, que aumenta gradativamente até atingir as dimensões máximas definidas pelo usuário, o limite máximo da janela deve estar correlacionado com a dimensão do maior elemento não pertencente ao terreno (Zhang et al., 2003).

3.3.2.2 Filtro simulador de tecidos

O filtro simulador de tecidos atua aplicando a ação da gravidade sobre um tecido a recobrir a nuvem de pontos invertida, de tal modo é possível determinar a localização dos nós do tecido para gerar uma aproximação da superfície do solo. Os pontos no solo podem ser extraídos da nuvem de pontos, comparando os pontos originais e a superfície gerada. (ZHANG et al., 2016).

O método é baseado na simulação de um processo físico simples, consiste em um pedaço de pano é colocado sobre um terreno e, em seguida, esse pano cai por causa da gravidade. Supondo que o pano seja macio o suficiente para grudar na superfície, a forma final do pano é o MDS (modelo digital de superfície). No entanto, se o terreno for virado de cabeça para baixo e o pano é depositado na superfície invertida e com certa resistência, a forma final do pano neste caso será o MDT (modelo digital do terreno), resumidamente apresentada na Figura 18.

Como as forças internas e externas variam com o tempo t , a Equação geralmente é resolvida por uma integração numérica.

No início da filtragem a grade de partículas que simulará a ação do tecido é disposto acima da nuvem de pontos LiDAR invertida, a seguir é aplicado a ação da gravidade na grade de partículas, onde alguns pontos interceptaram a nuvem de pontos LiDAR em tempos diferentes.

Os pontos da grade interceptados pela nuvem de pontos invertida, são definidos como pontos fixos e assumem as coordenadas de interseção, os pontos ainda móveis, então sofrem ação das forças dos pontos vizinhos e são ajustados de acordo simulando a deposição de um tecido sobre uma superfície. O processo de simulação é iterativo, e interrompido quando a variação em altura das partículas entre as iterações é considerada mínima ou quando atingir o número máximo de iterações.

A classificação é definida por um limiar de distância entre a superfície modelada pela grade de partículas e a nuvem de pontos. Os pontos menores que o limiar, são classificados como pontos pertencentes ao solo e os demais a elementos da superfície.

3.3.3 Normalização de nuvens de pontos

Para eliminar os efeitos das variações de altimetria nos povoamentos estudados, ou obter as alturas absolutas das árvores, o processo de normalização da nuvem é empregado, levando em consideração a classificação da nuvem de pontos, onde é gerada uma superfície correspondente ao terreno e os pontos são subtraídos da mesma, resultando na nuvem normalizada (SANTOS, 2018), seguindo a equação a seguir.

$$\text{Nuvem normalizada} = \text{nuvem original} - \text{MDT} \quad (9)$$

A nuvem normalizada representa a altura dos objetos acima do solo, não mais a altitude a um referencial. O processo de normalização pode adicionar erros em processos de segmentação, pois a forma das copas das árvores é alterada, principalmente em regiões de relevo acentuado (BARBOSA, 2017).

3.3.4 Modelagem digital

Alguns dos algoritmos de contagem aceitam como entrada apenas dados raster, para tal a modelagem digital é necessária. Os modelos digitais resumem-se em três, o modelo digital de elevação (MDE) oriundo da nuvem de pontos bruta, o modelo digital de alturas (MDA) obtido da nuvem de pontos normalizada e o modelo digital de terreno (MDT) que representa a modelagem do terreno e não utilizado diretamente na contagem de árvores, mas que proporciona produtos derivados como a nuvem de pontos normalizada e o modelo digital de alturas.

3.3.4.1 Interpolador ponderado inverso da distância

O interpolador ponderado inverso da distância, comumente conhecido como *Inverse Distance Weighting* (IDW), aplica uma média ponderada em função de N pontos conhecidos (SILVA, 2011), qual preserva os dados originais (ZANDONÁ et al., 2005). A interpolação é controlada por uma potência de ponderação em função da distância, onde a influência é menor para os pontos mais afastados do local foco da interpolação, já os pontos próximos a posição de determinação atuam de modo mais significativos na construção da superfície. (YANG et al., 2004).

O estimador pode ser resumido pela equação a seguir.

$$z(x_o) = \frac{\sum_{i=1}^n \frac{z(x_i)}{d_{ij}^\beta}}{\sum_{i=1}^n \frac{1}{d_{ij}^\beta}} \quad (10)$$

Em que:

$z(x_o)$ = Estimativa do ponto não amostrado

$z(x_i)$ = Ponto conhecido amostrado

d_{ij} = Distância da amostra ao ponto a ser estimado

n = Número de pontos amostrados

β = Expoente de ponderação


3.3.4.2 Rede de triângulos irregulares

A interpolação por triângulos irregulares, também chamada de *Triangulated Irregular Network* (TIN), e comumente conhecida por fazer uso do método de triangulação de Delaunay, cria uma superfície de triângulos formada por pontos vizinhos, em geral tem boa reconstrução da superfície (CHAO et al., 2015), com exceção das bordas onde os triângulos assumem ângulos internos pequenos, os efeitos de borda da modelagem TIN podem ser controlados aplicando limites aceitáveis de arestas (ZHAO et al., 2016).

A triangulação de Delaunay deve atender a alguns critérios, que consiste na construção de triângulos visando a maximização dos ângulos internos, aproximando-os o máximo possível de um triângulo equilátero.

Para atender por completo a triangulação de Delaunay, um círculo formado pelos vértices do triângulo não deve conter nenhum outro vértice da nuvem de pontos no seu interior, vértices na aresta do círculo são aceitáveis (CERQUEIRA, 2010), tal condição é apresentada na Figura 9.

FIGURA 19 - CONDIÇÃO DE DELAUNAY



FONTE: Cerqueira (2010).

O conjunto (a) apresenta a condição de Delaunay atendida, onde no círculo formado pelos vértices do triângulo está vazio, já a conjunto (b) não atende a condição pois o círculo retorna um vértice não pertencente ao triângulo testado. Nota-se que a posição dos pontos é a mesma nos dois casos, alterando-se apenas as suas arestas.

3.3.4.3 Rede de triângulos irregulares com restrição

Com o objetivo de otimizar a modelagem, a triangulação Delaunay pode ter critérios adicionais, é o exemplo da rede de triângulos irregulares com restrição, implementada na biblioteca LidR e podendo ser executada pela função DSMTIN.

Seguindo as mesmas condições originais da triangulação de Delaunay, quando aplicada a função citada anteriormente, na execução da triangulação são utilizados somente os pontos LiDAR referentes ao primeiro retorno, com a opção de limitar a dimensão de aresta máxima aceitável, com a finalidade de eliminar triângulos alongados que ainda atendam o critério de Delaunay, efeito comum nas bordas da rede triangulada.

3.3.4.4 Rede de triângulos irregulares livre de poços

O método também conhecido como *pitfree*, baseado no conceito da triangulação de Delaunay, visa a criação de um modelo digital de superfície sem a presença de buracos, comuns em superfícies derivadas de dados LiDAR com mais de um retorno por pulso ou quando o pulso LiDAR penetra através dos galhos de um dossel florestal antes de produzir um primeiro retorno (GAVEAU e HILL, 2003).

É gerado preliminarmente um modelo digital com todos os primeiros retornos que compõe a nuvem de pontos LiDAR em seguida acontece na construção de modelos digitais parciais em limites altimétricos que correspondem a alturas ou altitudes pré-definidas e a posterior combinação dos modelos digitais gerados, criando um modelo digital final somente com o valor mais alto em cada posição x e y, gerando um modelo final livre de buracos ou poços (KHOSRAVIPOUR et al., 2014).

Para a identificação de árvores o tamanho do pixel na construção do modelo é um parâmetro essencial (CHEN et al., 2006), pixels com 30% do diâmetro da copa são suficientes para a viabilização da modelagem de copas (KHOSRAVIPOUR et al., 2014).

3.3.5 Dados tratados

Após o tratamento dos dados, que incluem a remoção de *outliers*, classificação, normalização e construção de modelos digitais, cada talhão conta com

um conjunto de 15 dados com diferentes tratamentos, que consistem em 3 nuvens de pontos, 4 modelos digitais de elevação e 8 modelos digitais de altura, apresentados na tabela 3.

TABELA 3 - TRATAMENTOS E TIPOS DE DADOS, APÓS O PRÉ-PROCESSAMENTO

Tratamento	Classificação	Interpolação	Normalizado	Formato da informação
1	não classificado	não interpolado	não	Nuvem de pontos
2	pmf	não interpolado	sim	Nuvem de pontos
3	csf	não interpolado	sim	Nuvem de pontos
4	não classificado	pitfree	não	MDE
5	não classificado	tin	não	MDE
6	não classificado	idw	não	MDE
7	não classificado	dsmtin	não	MDE
8	pmf	pitfree	sim	MDA
9	pmf	tin	sim	MDA
10	pmf	idw	sim	MDA
11	pmf	dsmtin	sim	MDA
12	csf	pitfree	sim	MDA
13	csf	tin	sim	MDA
14	csf	idw	sim	MDA
15	csf	dsmtin	sim	MDA

Em que: fmp = filtro morfológico progressivo; csf = *cloth simulation filter* (filtro simulador de tecidos); pitfree = rede de triângulos irregulares livre de poços; tin = rede de triângulos irregulares; idw = interpolador ponderado inverso da distância; dsmtin = rede de triângulos irregulares com restrição; MDE = Modelo digital de elevação; MDA = Modelo digital de altura.

FONTE: O Autor (2020).

3.4 ALGORITMOS DE CONTAGEM AVALIADOS

3.4.1 Filtro de máxima local

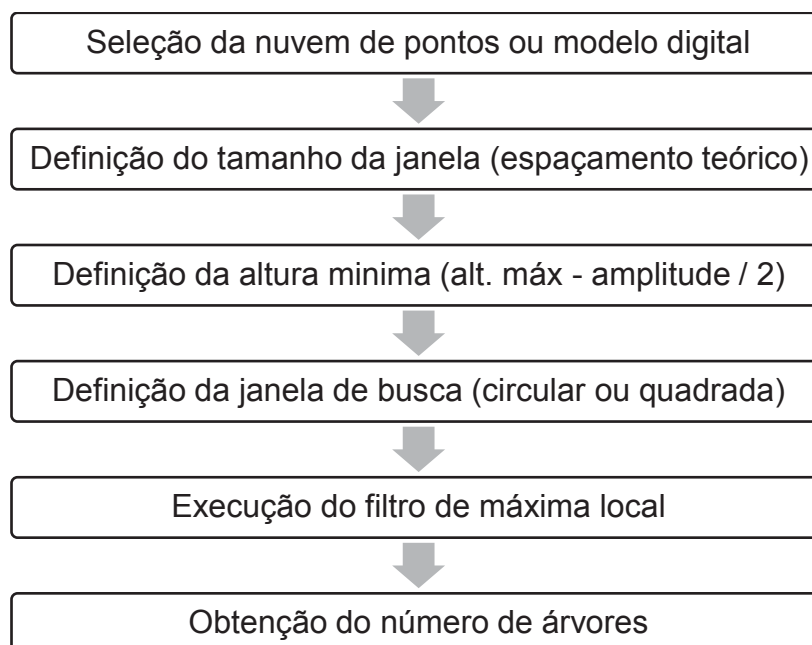
A função de máxima local, aceita como entrada de dados, uma nuvem de pontos, um modelo digital de copas ou um modelo digital de elevação, os quais foram aplicados em diferentes formatos de janela de busca assim como combinações de dimensões de janela fixas e janelas de dimensões variáveis em função da altura das árvores.

3.4.1.1 Janela de busca fixa

A primeira abordagem para a identificação de árvores utilizando o filtro de máxima local, foi a implementação de janelas de busca com dimensões fixas, visando a maior automatização possível a definição da dimensão destas janelas adotou-se o espaçamento teórico de cada talhão. As janelas podem ser definidas como circulares onde é informado o diâmetro da janela de busca ou quadrada informando a aresta da janela de busca.

Para minimizar os erros na identificação das árvores, foi definida uma altura mínima de pesquisa, que corresponde à metade da amplitude em altura do talhão. A implementação do filtro de máxima local com janela fixa, consiste na seleção dos dados de entrada, em seguida definida a dimensão da janela de busca fixa, a altura mínima de busca, o formato da janela de busca (circular ou quadrada), para posterior execução da identificação das árvores pelo filtro de máxima local, o processo é exemplificado na Figura 20.

FIGURA 20 - FILTRO DE MÁXIMA LOCAL, COM JANELA DE BUSCA FIXA.



FONTE: O Autor (2020).

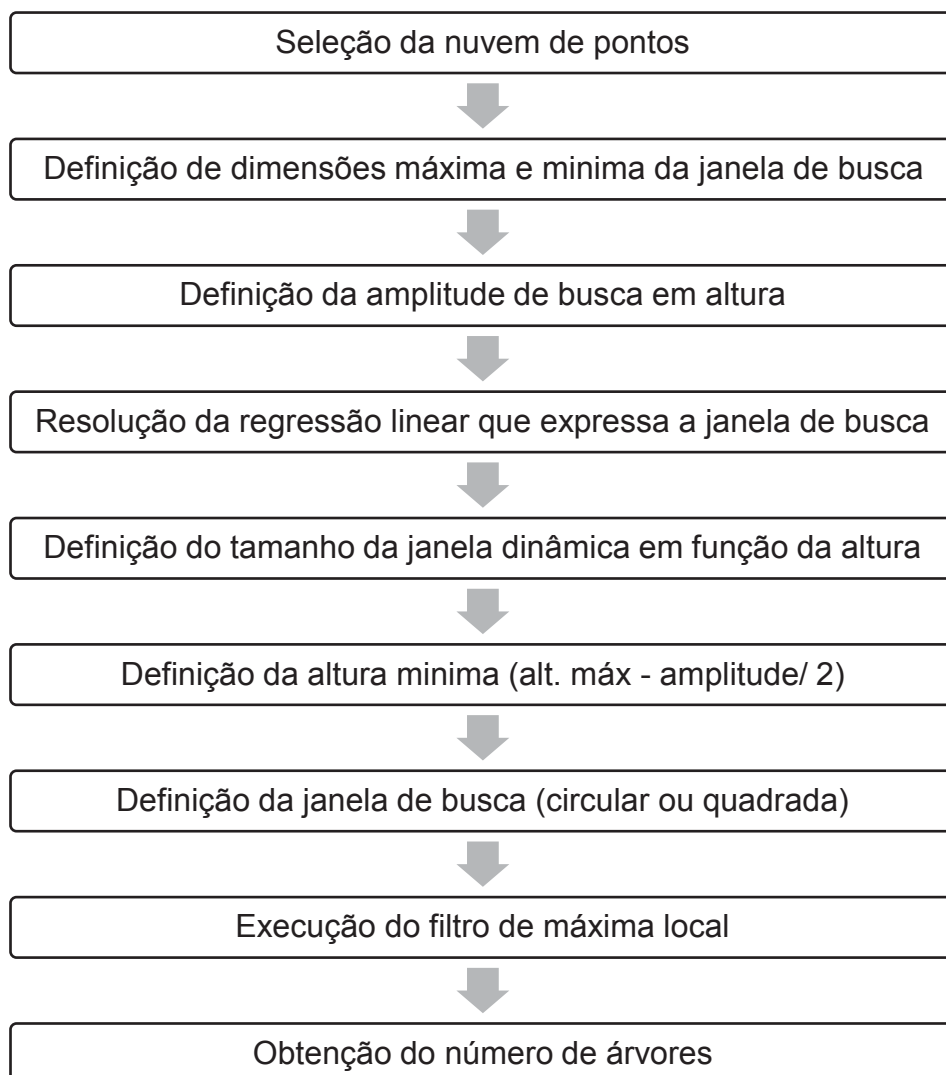
3.4.1.2 Janela de busca móvel em função da altura

A implementação do filtro de máxima local com janela de busca móvel, considera os mesmos parâmetros de entrada de dados, altura mínima e o formato da janela, conforme descritos no item anterior, porém o diâmetro ou arestas das janelas são definidos em função da altura.

Foram adotadas duas abordagens para a função do tamanho da janela móvel, a primeira o tamanho é proporcional à altura e a segunda o tamanho da janela é inversamente proporcional à altura.

A função que expressa a janela móvel é resolvida por uma regressão linear, onde os coeficientes são calculados de acordo com as informações do talhão e espaçamento de modo automatizado e então a janela de busca definida em função da altura, qual se comporta de modo dinâmico a cada nova busca. A Figura 21 apresenta as etapas na execução da janela de busca móvel.

FIGURA 21 - FILTRO DE MÁXIMA LOCAL, COM JANELA DE BUSCA MÓVEL.



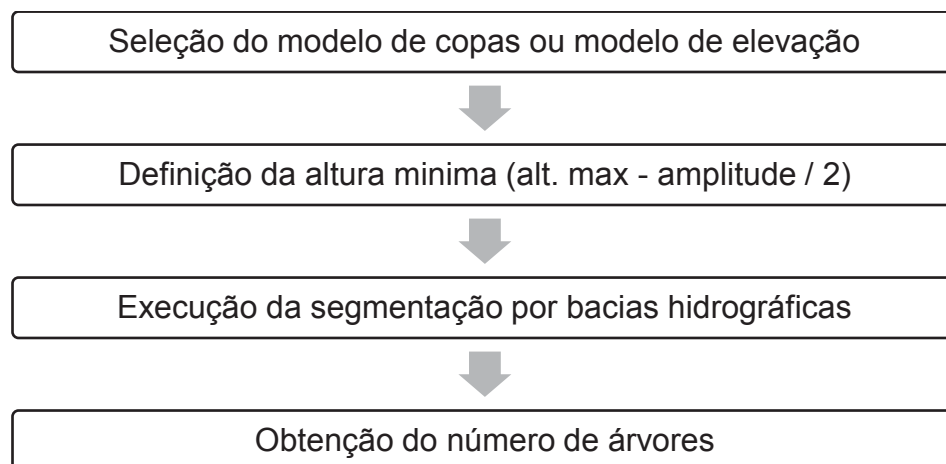
FONTE: O Autor (2020).

3.4.2 Segmentação por bacias hidrográficas

Outro modo de obtenção do número de árvores é a segmentação por bacias hidrográficas, o qual faz uso de um modelo digital de copas ou um modelo de elevação, neste caso as copas das árvores são delimitadas e tratadas como se fossem bacias hidrográficas, permitindo assim a segmentação de cada árvore do talhão e por consequência a contagem de indivíduos.

Como entrada foram adotados modelos digitais de alturas e modelos digitais de elevação, obtidos da nuvem de pontos por meio dos algoritmos de modelagem digital descritos anteriormente (*idw*, *tin*, *dsmtin* e *pitfree*), e limite de altura, a metade da amplitude altimétrica da nuvem de pontos que deu origem ao modelo digital, com a finalidade de restringir que erroneamente dados de baixa altura sejam interpretados como uma árvore. Na Figura 22 é apresentada a aplicação do método, com parâmetros de entrada e a restrição em altura.

FIGURA 22 - SEGMENTAÇÃO POR BACIAS HIDROGRÁFICAS.



FONTE: O Autor (2020).

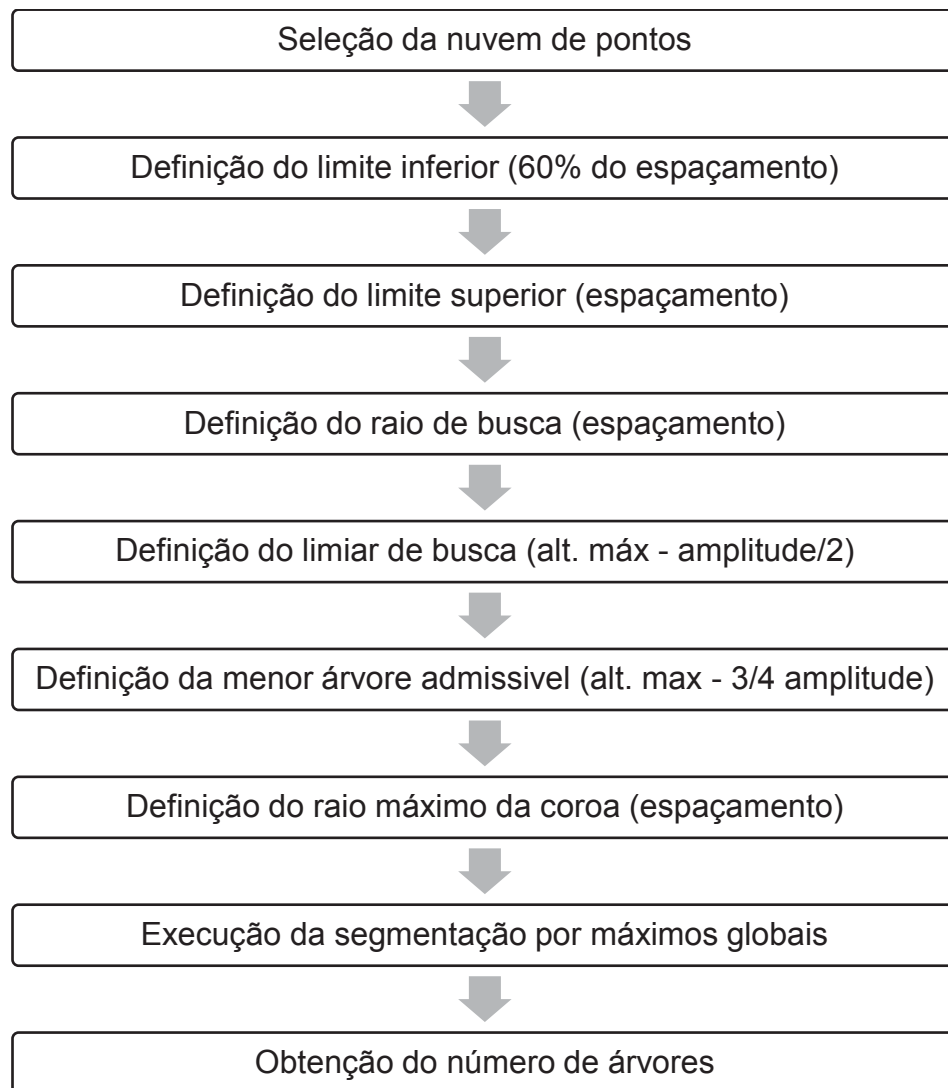
3.4.3 Filtro de máximos globais

O último algoritmo testado, consiste em um método qual aplica o filtro de máximos globais, proposto por Li (2012), que trabalha a nível de nuvem de pontos com a finalidade de segmentar árvores individualmente.

Foram definidos os limites superior e inferior que correspondem aos espaçamentos horizontais teóricos admissíveis do ápice das copas e das prováveis

bases, quais são aplicados em função da altura e do limiar de busca, ainda foram definidos o raio de busca e a altura mínima admissível, a Figura 23 descreve o processo de implementação do algoritmo em questão.

FIGURA 23 - SEGMENTAÇÃO PELO FILTRO DE MÁXIMOS GLOBAIS



FONTE: O Autor (2020).

3.5 EXECUÇÃO DA CONTAGEM

A combinação da execução dos algoritmos de contagem e do tratamento dos dados LiDAR, atingiu 105 cenários diferentes. Para tal, foram consideradas as nuvem de pontos brutas, as nuvem de pontos normalizadas, previamente filtradas por 2 filtros distintos (filtro simulador de tecidos e o filtro morfológico progressivo), um modelo digital de elevação e modelos digitais de alturas provenientes das nuvens de ponto

normalizadas, onde foram empregadas 4 metodologias de interpolação para construção das superfícies (*idw*, *tin*, *dsmtin* e *pitfree*).

O filtro de máximos globais aceita somente nuvens de pontos como dados de entrada. O algoritmo de segmentação por bacias hidrográficas aceita como entrada apenas dados *raster* que correspondem aos modelos digitais de elevação e aos modelos digitais de altura.

O filtro de máxima local aceita como dados de entrada a nuvem de pontos ou uma superfície em formato *raster*, além de possibilitar mais opções de busca, como o formato da janela de busca (circular ou quadrada), e dimensões da janela fixa ou móvel, no caso da janela móvel foram definidas duas possibilidades uma proporcional à altura e outra inversamente proporcional à altura.

A Tabela 4 apresenta as possibilidades de combinações dos 105 cenários possíveis e suas combinações entre algoritmos, dados de entrada, parâmetros de busca (formato e dimensão da janela de busca), métodos de classificação, métodos de modelagem digital e aplicação da normalização da nuvem de pontos.

TABELA 4 - CENÁRIOS ORIUNDOS DAS COMBINAÇÕES ENTRE ALGORITMOS DE IDENTIFICAÇÃO E DADOS DE ENTRADA

Cenário	Algoritmo	Formato do dado de entrada	Dimensão da janela de busca	Formato da janela de busca	Método de classificação da nuvem de pontos	Normalização da nuvem de pontos	Método de modelagem digital
1	fml	NP	fixa	Circular	pmf	sim	-
2	fml	NP	fixa	Quadrada	pmf	sim	-
3	fml	MDA	fixa	Circular	pmf	sim	pitfree
4	fml	MDA	fixa	Quadrada	pmf	sim	pitfree
5	fml	MDA	fixa	Circular	pmf	sim	tin
6	fml	MDA	fixa	Quadrada	pmf	sim	tin
7	fml	MDA	fixa	Circular	pmf	sim	idw
8	fml	MDA	fixa	Quadrada	pmf	sim	idw
9	fml	MDA	fixa	Circular	pmf	sim	dsmtin
10	fml	MDA	fixa	Quadrada	pmf	sim	dsmtin
11	fml	NP	fixa	Circular	csf	sim	-
12	fml	NP	fixa	Quadrada	csf	sim	-
13	fml	MDA	fixa	Circular	csf	sim	pitfree
14	fml	MDA	fixa	Quadrada	csf	sim	pitfree
15	fml	MDA	fixa	Circular	csf	sim	tin
16	fml	MDA	fixa	Quadrada	csf	sim	tin
17	fml	MDA	fixa	Circular	csf	sim	idw
18	fml	MDA	fixa	Quadrada	csf	sim	idw
19	fml	MDA	fixa	Circular	csf	sim	dsmtin

Cenário	Algoritmo	Formato do dado de entrada	Dimensão da janela de busca	Formato da janela de busca	Método de classificação da nuvem de pontos	Normalizaçã o da nuvem de pontos	Método de modelagem digital
20	fml	MDA	fixa	Quadrada	csf	sim	dsmtin
21	fml	NP	fixa	Circular	-	-	-
22	fml	NP	fixa	Quadrada	-	-	-
23	fml	MDE	fixa	Circular	-	-	pitfree
24	fml	MDE	fixa	Quadrada	-	-	pitfree
25	fml	MDE	fixa	Circular	-	-	tin
26	fml	MDE	fixa	Quadrada	-	-	tin
27	fml	MDE	fixa	Circular	-	-	idw
28	fml	MDE	fixa	Quadrada	-	-	idw
29	fml	MDE	fixa	Circular	-	-	dsmtin
30	fml	MDE	fixa	Quadrada	-	-	dsmtin
31	fml	NP	prop. alt.	Quadrada	pmf	sim	-
32	fml	NP	prop. alt.	Circular	pmf	sim	-
33	fml	MDA	prop. alt.	Quadrada	pmf	sim	pitfree
34	fml	MDA	prop. alt.	Circular	pmf	sim	pitfree
35	fml	MDA	prop. alt.	Quadrada	pmf	sim	tin
36	fml	MDA	prop. alt.	Circular	pmf	sim	tin
37	fml	MDA	prop. alt.	Quadrada	pmf	sim	idw
38	fml	MDA	prop. alt.	Circular	pmf	sim	idw
39	fml	MDA	prop. alt.	Quadrada	pmf	sim	dsmtin
40	fml	MDA	prop. alt.	Circular	pmf	sim	dsmtin
41	fml	NP	prop. alt.	Quadrada	csf	sim	-
42	fml	NP	prop. alt.	Circular	csf	sim	-
43	fml	MDA	prop. alt.	Quadrada	csf	sim	pitfree
44	fml	MDA	prop. alt.	Circular	csf	sim	pitfree
45	fml	MDA	prop. alt.	Quadrada	csf	sim	tin
46	fml	MDA	prop. alt.	Circular	csf	sim	tin
47	fml	MDA	prop. alt.	Quadrada	csf	sim	idw
48	fml	MDA	prop. alt.	Circular	csf	sim	idw
49	fml	MDA	prop. alt.	Quadrada	csf	sim	dsmtin
50	fml	MDA	prop. alt.	Circular	csf	sim	dsmtin
51	fml	NP	prop. alt.	Quadrada	-	-	-
52	fml	NP	prop. alt.	Circular	-	-	-
53	fml	MDE	prop. alt.	Quadrada	-	-	pitfree
54	fml	MDE	prop. alt.	Circular	-	-	pitfree
55	fml	MDE	prop. alt.	Quadrada	-	-	tin
56	fml	MDE	prop. alt.	Circular	-	-	tin
57	fml	MDE	prop. alt.	Quadrada	-	-	idw
58	fml	MDE	prop. alt.	Circular	-	-	idw
59	fml	MDE	prop. alt.	Quadrada	-	-	dsmtin
60	fml	MDE	prop. alt.	Circular	-	-	dsmtin
61	fml	NP	inv. prop. alt.	Quadrada	pmf	sim	-

Cenário	Algoritmo	Formato do dado de entrada	Dimensão da janela de busca	Formato da janela de busca	Método de classificação da nuvem de pontos	Normalizaçã o da nuvem de pontos	Método de modelagem digital
62	fml	NP	inv. prop. alt.	Circular	pmf	sim	-
63	fml	MDA	inv. prop. alt.	Quadrada	pmf	sim	pitfree
64	fml	MDA	inv. prop. alt.	Circular	pmf	sim	pitfree
65	fml	MDA	inv. prop. alt.	Quadrada	pmf	sim	tin
66	fml	MDA	inv. prop. alt.	Circular	pmf	sim	tin
67	fml	MDA	inv. prop. alt.	Quadrada	pmf	sim	idw
68	fml	MDA	inv. prop. alt.	Circular	pmf	sim	idw
69	fml	MDA	inv. prop. alt.	Quadrada	pmf	sim	dsmtin
70	fml	MDA	inv. prop. alt.	Circular	pmf	sim	dsmtin
71	fml	NP	inv. prop. alt.	Quadrada	csf	sim	-
72	fml	NP	inv. prop. alt.	Circular	csf	sim	-
73	fml	MDA	inv. prop. alt.	Quadrada	csf	sim	pitfree
74	fml	MDA	inv. prop. alt.	Circular	csf	sim	pitfree
75	fml	MDA	inv. prop. alt.	Quadrada	csf	sim	tin
76	fml	MDA	inv. prop. alt.	Circular	csf	sim	tin
77	fml	MDA	inv. prop. alt.	Quadrada	csf	sim	idw
78	fml	MDA	inv. prop. alt.	Circular	csf	sim	idw
79	fml	MDA	inv. prop. alt.	Quadrada	csf	sim	dsmtin
80	fml	MDA	inv. prop. alt.	Circular	csf	sim	dsmtin
81	fml	NP	inv. prop. alt.	Quadrada	-	-	-
82	fml	NP	inv. prop. alt.	Circular	-	-	-
83	fml	MDE	inv. prop. alt.	Quadrada	-	-	pitfree
84	fml	MDE	inv. prop. alt.	Circular	-	-	pitfree
85	fml	MDE	inv. prop. alt.	Quadrada	-	-	tin
86	fml	MDE	inv. prop. alt.	Circular	-	-	tin
87	fml	MDE	inv. prop. alt.	Quadrada	-	-	idw
88	fml	MDE	inv. prop. alt.	Circular	-	-	idw
89	fml	MDE	inv. prop. alt.	Quadrada	-	-	dsmtin
90	fml	MDE	inv. prop. alt.	Circular	-	-	dsmtin
91	sbh	MDA	variável	Irregular	pmf	sim	pitfree
92	sbh	MDA	variável	Irregular	pmf	sim	tin
93	sbh	MDA	variável	Irregular	pmf	sim	idw
94	sbh	MDA	variável	Irregular	pmf	sim	dsmtin
95	sbh	MDA	variável	Irregular	csf	sim	pitfree
96	sbh	MDA	variável	Irregular	csf	sim	tin
97	sbh	MDA	variável	Irregular	csf	sim	idw
98	sbh	MDA	variável	Irregular	csf	sim	dsmtin
99	sbh	MDE	variável	Irregular	-	-	pitfree
100	sbh	MDE	variável	Irregular	-	-	tin
101	sbh	MDE	variável	Irregular	-	-	idw
102	sbh	MDE	variável	Irregular	-	-	dsmtin
103	fmg	NP	variável	Irregular	pmf	sim	-

Cenário	Algoritmo	Formato do dado de entrada	Dimensão da janela de busca	Formato da janela de busca	Método de classificação da nuvem de pontos	Normalização da nuvem de pontos	Método de modelagem digital
104	fmg	NP	variável	Irregular	csf	sim	-
105	fmg	NP	variável	Irregular	-	-	-

Em que: fml = filtro de máxima local; sbh = segmentação por bacias hidrográficas; fmg = filtro de máximas globais; NP = Nuvem de pontos LiDAR; MDA = Modelo digital de altura; MDE = Modelo digital de elevação; prop.alt = proporcional à altura; inv. prop.alt = inversamente proporcional à altura; fmp = filtro morfológico progressivo; csf = *cloth simulation filter* (filtro simulador de tecidos); pitfree = rede de triângulos irregulares livre de poços; tin = rede de triângulos irregulares; idw = interpolador ponderado inverso da distância; dsmtin = rede de triângulos irregulares com restrição;

FONTE: O Autor (2020).

3.6 AVALIAÇÃO DOS ALGORITMOS

Para cada cenário será apresentado o valor de acurácia por talhão, qual relaciona o valor obtido via algoritmo e o censo florestal, adotando o valor do censo como o valor real para o número de árvores do respectivo talhão, os algoritmos serão classificados de acordo com a sua aderência ao valor real, onde o acerto deve ser superior a 80% do número de árvores (MOHAN et al., 2017).

Para a definição de uma solução genérica ou indicar o melhor algoritmo para a detecção e contagem de árvores, estatísticas de comparação devem ser aplicadas relacionando o número de árvores real do talhão obtivo via censo florestal e o número de árvores obtido via algoritmos de detecção em conjunto com dados LiDAR.

O desempenho dos algoritmos testados foi realizado com base em testes estatísticos, sendo eles: acurácia (a), raiz do erro médio quadrático ($RMSE$), erro médio absoluto (MAE), coeficiente de eficiência (E), índice de concordância de Willmott (d) e índice de desempenho (c).

A acurácia (a) trata da distância direta entre o valor observado e o valor estimado, representando o percentual de acerto de uma determinada estimativa, valores próximos a 100% são ideais (LEGATES et. al, 1999), pode ser obtido de acordo com a seguinte equação.

$$a = \frac{O_i}{P_i} \cdot 100 \quad (11)$$

Em que:

O_i = valor observado (censo);

P_i = valor predito (algoritmo).

O *RMSE* trata da medida desvio médio entre o valor observado e predito, valores preferíveis se encontram próximos a zero (LEGATES et. al, 1999), definidos pela seguinte equação.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (12)$$

Em que:

n = número de observações;

O_i = valor observado (censo);

P_i = valor predito (algoritmo).

O erro médio absoluto (*MAE*), representa o desvio médio entre observado e predito. O *RMSE* dá um peso maior para desvios grandes (pois são elevados ao quadrado), enquanto o *MAE* dá um peso igual a todos os desvios, e pode ser apresentado em valores relativos a média das observações, valores baixos próximos a zero representam baixo erro médio absoluto (LEGATES et. al, 1999), são definidos com as equações a seguir.

$$MAE = \frac{\sum_{i=0}^n |O_i - P_i|}{n} \quad (13)$$

Em que:

n = número de observações;

O_i = valor observado (censo);

P_i = valor predito (algoritmo).

O Coeficiente de eficiência (*E*), ou coeficiente de Nash-Sutcliffe, é utilizado com muita frequência para a avaliação de modelos. Seu valor fica entre $-\infty$ e 1, e

quanto maior o valor, melhor a concordância com as observações, representando uma concordância total entre predito e observado (LEGATES et. al, 1999). É definido conforme a equação apresentada a seguir.

$$E = \frac{\sum_{i=0}^n (O_i - P_i)^2}{\sum_{i=0}^n (O_i - \bar{O})^2} \quad (14)$$

Em que:

P_i = valor predito (algoritmo);

O_i = valor observado (censo);

\bar{O} = média dos valores observados.

O índice de concordância de Willmott (d), apresenta a concordância entre os valores observados e preditos, onde valor do índice atua entre 0 e 1, e quanto maior seu valor, melhor o desempenho (LEGATES et. al, 1999), pode ser obtido pela equação a seguir.

$$d = 1 - \frac{\sum_{i=0}^n (O_i - P_i)^2}{\sum_{i=0}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (15)$$

Em que:

P_i = valor predito (algoritmo);

O_i = valor observado (censo);

\bar{O} = média dos valores observados.

O índice de desempenho (c), mescla precisão e exatidão, a precisão proveniente do coeficiente de correlação de Pearson (r) qual indica o grau de dispersão de observações a média, e a exatidão que indica o afastamento dos valores preditos em relação aos observados, qual é dado pelo índice de concordância de Willmott (d) (CAMARGO et. al, 1997). Os valores para o índice de desempenho (c), seguem uma classificação para sua interpretação, apresentada na Tabela 5.

TABELA 5 – VALORES DE CLASSIFICAÇÃO DE ACORDO COM O ÍNDICE DE DESEMPENHO

Índice de desempenho (c)	Classificação
>0,85	Ótimo
0,76 – 0,85	Muito Bom
0,66 – 0,75	Bom
0,61 – 0,65	Mediano
0,51 – 0,60	Sofrível
0,41 – 0,50	Mal
<0,40	Péssimo

FONTE: Adaptado de (CAMARGO et. al, 1997).

O índice de desempenho pode ser obtido pela seguinte equação.

$$c = d * \frac{\sum_{i=0}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=0}^n (O_i - \bar{O})^2 \sum_{i=0}^n (P_i - \bar{P})^2}} \quad (16)$$

Em que:

d = índice de concordância de Willmott;

P_i = valor predito (algoritmo);

\bar{P} = média dos valores preditos.

O_i = valor observado (censo);

\bar{O} = média dos valores observados.

4 RESULTADOS

4.1 CENSO FLORESTAL

Os cinco talhões em estudo, foram submetidos a contagem de indivíduos ao nível de censo, contabilizados o total de 48.008 fustes e 879 linhas para os 5 talhões do estudo, conforme a Tabela 6.

TABELA 6 - CENSO QUANTITATIVO DOS TALHÕES

	D2A	D4A	D5A	F9B	H1A	Total
nº de linhas	150	265	94	210	160	879
nº de árvores	5.759	11.550	4.212	11.312	15.175	48.008

FONTE: O Autor (2020).

4.2 PROCESSAMENTO DE DADOS LIDAR

As nuvens de pontos LiDAR foram submetidas a um filtro de remoção de *outliers*, visando eliminar pontos discrepantes na nuvem e que possam ser interpretados erroneamente nas etapas seguintes de filtragem, modelagem de copas, segmentação e contagem, propagando assim os erros iniciais de coleta de dados.

Para a remoção desses erros, foi utilizado o *software* Cloud Compare e executado o algoritmo *Statistical Outlier Removal* (SOR), o qual analisa o comportamento dos pontos vizinhos. Com base nos vizinhos mais próximos, são determinadas distancias médias e respectivos desvios, qual definirá a distância máxima permitida entre pontos, pontos acima da distância máxima serão classificados com *outliers*, e consequentemente eliminados da nuvem de pontos. (RUSU et al., 2008)

4.2.1 Qualidade da nuvem LiDAR

As nuvens de pontos LiDAR foram analisadas em função da sua consistência de distribuição, de acordo com os parâmetros de levantamento a densidade esperada é de 5 pontos/m². Tal informação foi obtida pela função *grid_density* do pacote LidR, onde os parâmetros de entrada são a nuvem de pontos LiDAR e a dimensão da célula de interesse.

A densidade de pontos esperada para a nuvem foi diferente da densidade de pontos obtida, em função de condições do levantamento e eliminação de *outliers*, atingindo para os talhões em estudo uma densidade média mínima de 3,06 pontos por m² (talhão D4A) e densidade média máxima de 4,91 pontos por m² (talhão D5A) com até 3 retornos por pulso. A Tabela 7 apresenta as condições das nuvens a respeito do número de pontos, retornos e densidade para cada talhão.


TABELA 7 – DENSIDADE E RETORNOS DAS NUVENS DE PONTOS LIDAR, DOS TALHÕES EM ESTUDO

	D2A	D4A	D5A	F9B	H1A
nº de pontos	177.830	305.623	193.427	289.424	347.398
1º retorno	98,29%	98,48%	95,68%	96,49%	96,47%
2º retorno	1,70%	1,50%	4,21%	3,49%	3,51%
3º retorno	0,01%	0,02%	0,11%	0,02%	0,02%
Densidade média (pontos/m²)	3,13	3,06	4,91	3,86	3,36

FONTE: O Autor (2020).


Os pontos não são distribuídos uniformemente em função da densidade, a Figura 24, correspondente aos talhões de 10 anos de idade e a Figura 25, correspondente aos talhões de 15 anos de idade, ambas apresentam a densidade espacialmente distribuída, onde é possível verificar locais com diferentes concentrações de pontos/m². Os detalhes circulares (A e B) nas imagens visam apresentar de modo ampliado a condição de não uniformidade da densidade de pontos, onde em alguns locais os valores se encontram abaixo da média, representados por cores próximas ao branco.

FIGURA 24 - SUPERFÍCIE DE DENSIDADE DA NUVEM DE PONTOS LiDAR POR m^2 , PARA OS TALHÕES DE 10 ANOS DE IDADE



FONTE: O Autor (2020).

FIGURA 25 - SUPERFÍCIE DE DENSIDADE DA NUVEM DE PONTOS LiDAR POR m^2 , PARA OS TALHÕES DE 15 ANOS DE IDADE



FONTE: O Autor (2020).

4.2.2 Classificação e normalização de nuvem de pontos

Para a obter a nuvem normalizada e viabilizar a criação de um modelo digital de copas, qual apresenta a altura das árvores, a nuvem LiDAR necessita ser classificada, foram implementados dois métodos de classificação, o filtro morfológico progressivo (pmf) e o filtro simulador de tecidos (csf).

O filtro morfológico progressivo implementado por Zhang (2003), faz uso de operações de dilatação e erosão para executar a classificação da nuvem de pontos, este tipo de operação demanda da entrada de uma janela de busca (definida como

igual ao espaçamento teórico do talhão) e de um valor de desnível máximo acima do solo (definido com a amplitude absoluta da nuvem de pontos, obtida automaticamente sobre a nuvem de pontos LiDAR).

O filtro simulador de tecidos implementado por Zhang (2016), qual simula uma malha sobre a nuvem de pontos LiDAR inversa, no qual a malha se ajusta com determinada rigidez aos pontos com menor altitude global, classificando como pontos de solo os mais próximos a malha simulada e os demais como pontos não pertencentes ao solo. Para a aplicação desse método não são necessários a definição de parâmetros de entrada além da nuvem de pontos LiDAR, pois os parâmetros de rigidez do tecido são definidos pelo próprio método, não necessitando de intervenções do usuário.

Após a classificação da nuvem de pontos LiDAR, é viabilizado a normalização da nuvem, onde os pontos classificados como pontos de solo são a base da nuvem, utilizada para transformar as altitudes em alturas. Portanto, a nuvem normalizada apresenta valores referente à altura do dossel florestal em relação ao solo.

A classificação da nuvem de pontos LiDAR, viabiliza a normalização da nuvem, onde os pontos classificados como pontos de solo são a base da nuvem, utilizada para transformar as altitudes em alturas. Portanto, a nuvem normalizada apresenta valores referente à altura do dossel florestal em relação ao solo.

Quando analisadas as densidades de pontos por m², não foram encontradas discrepâncias significativas na aplicação dos métodos de classificação, a densidade de pontos por classe e respectivos algoritmos de classificação são apresentados na Tabela 8.

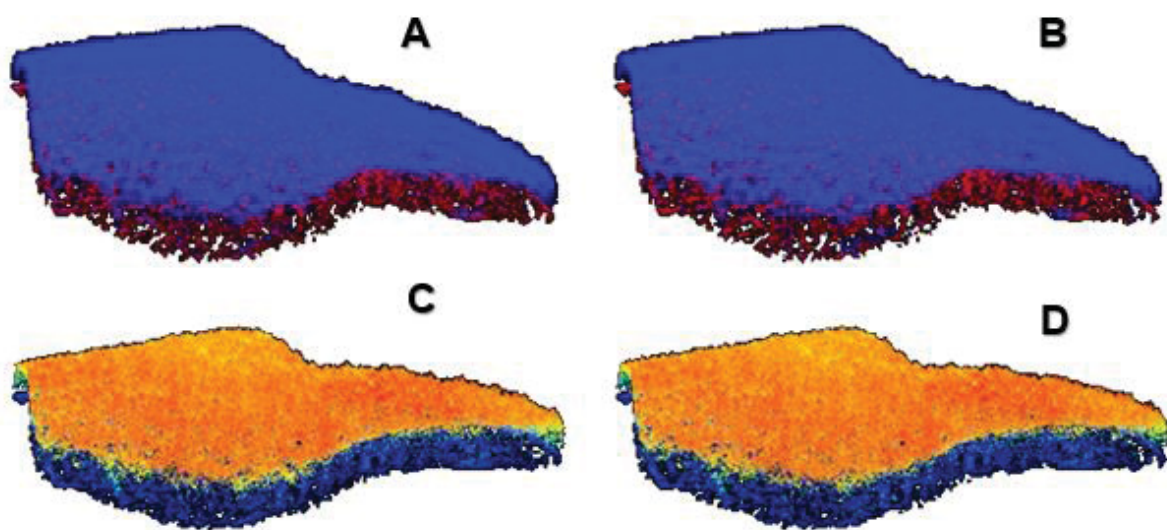
TABELA 8 - DENSIDADE DA NUVEM DE PONTOS CLASSIFICADA, POR CLASSE

Classe	Algoritmo de classificação	D2A	D4A	D5A	F9B	H1A
Solo	fmp	0,41	0,50	0,57	0,79	0,69
	csf	0,43	0,55	0,62	0,83	0,70
Não solo	fmp	2,72	2,56	4,34	3,07	2,67
	csf	2,70	2,51	4,29	3,03	2,66

FONTE: O Autor (2020). Em que: fmp = filtro morfológico progressivo; csf = *cloth simulation filter* (filtro simulador de tecidos).

Na Figura 26, pode-se observar que visualmente não são perceptíveis diferenças na classificação da nuvem de pontos, e consequentemente na normalização da nuvem. A nuvem de pontos A representa a nuvem de pontos classificada pelo filtro morfológico progressivo, a nuvem B a classificada pelo filtro simulador de tecidos, onde os pontos em vermelho são os classificados como pontos pertencentes ao solo e os azuis como elementos da superfície, a nuvem C corresponde a nuvem normalizada após ser classificada pelo filtro morfológico progressivo e a nuvem D, a nuvem de pontos normalizada após a classificação pelo filtro simulador de tecidos. A nuvem de pontos apresentada corresponde ao talhão D5A, as demais têm comportamento semelhante, onde em nenhuma delas é possível detectar diferenças visuais.

FIGURA 26 – COMPARATIVO DAS NUUVENS CLASSIFICADAS POR ALGORITMOS DISTINTOS E RESPECTIVAS NUUVENS NORMALIZADAS, PARA O TALHÃO D5A.



Em que: A = nuvem de pontos classificada pelo filtro morfológico progressivo; B = nuvem de pontos classificada pelo filtro simulador de tecidos; C= nuvem de pontos normalizada após ser classificada pelo filtro morfológico progressivo e D = nuvem de pontos normalizada após ser classificada pelo filtro simulador de tecidos.

FONTE: O Autor (2020).

4.2.3 Modelo digital de copas e elevação

O dossel florestal foi modelado em formato *raster*, seja para economia de espaço em disco ou, para a implementação das análises baseadas em dados *raster*,

para criação do modelo digital de copas foram utilizados 4 algoritmos, sendo eles: o interpolador ponderado inverso da distância (*idw*), a rede de triângulos irregulares (*tin*), a rede de triângulos irregulares com restrição (*dsmtin*) e a rede de triângulos irregulares livre de poços (*pitfree*).

O interpolador ponderado inverso da distância, o qual utiliza a abordagem vizinhos mais próximos, o número de vizinhos a ser utilizado pode ser definido pelo usuário, manteve-se os parâmetros genéricos do método no qual são utilizados 10 (dez) vizinhos mais próximos com potência igual a 2 (dois) para a ponderação inversa da distância.

A rede de triângulos irregulares, executa a modelagem de copas por interpolação espacial baseada na triangulação de Delaunay, o qual executa uma interpolação linear considerando triângulos mais equiláteros possíveis, na existência de pontos fora da área atingida pelos triângulos é executada uma extrapolação, não foram definidos parâmetros de controle do processo de interpolação ou extrapolação, utilizando-se do padrão previamente implementado na biblioteca lidR.

A rede de triângulos irregulares com restrição, que consiste na mesma abordagem da rede de triângulos irregulares, descrito anteriormente, porém sem a execução de extrapolações e com um valor máximo admissível para as arestas dos triângulos gerados pela triangulação de Delaunay. A aresta máxima foi definida em função do espaçamento teórico do povoamento (2,5m), onde os triângulos com arestas maiores que o espaçamento, são removidos da superfície.

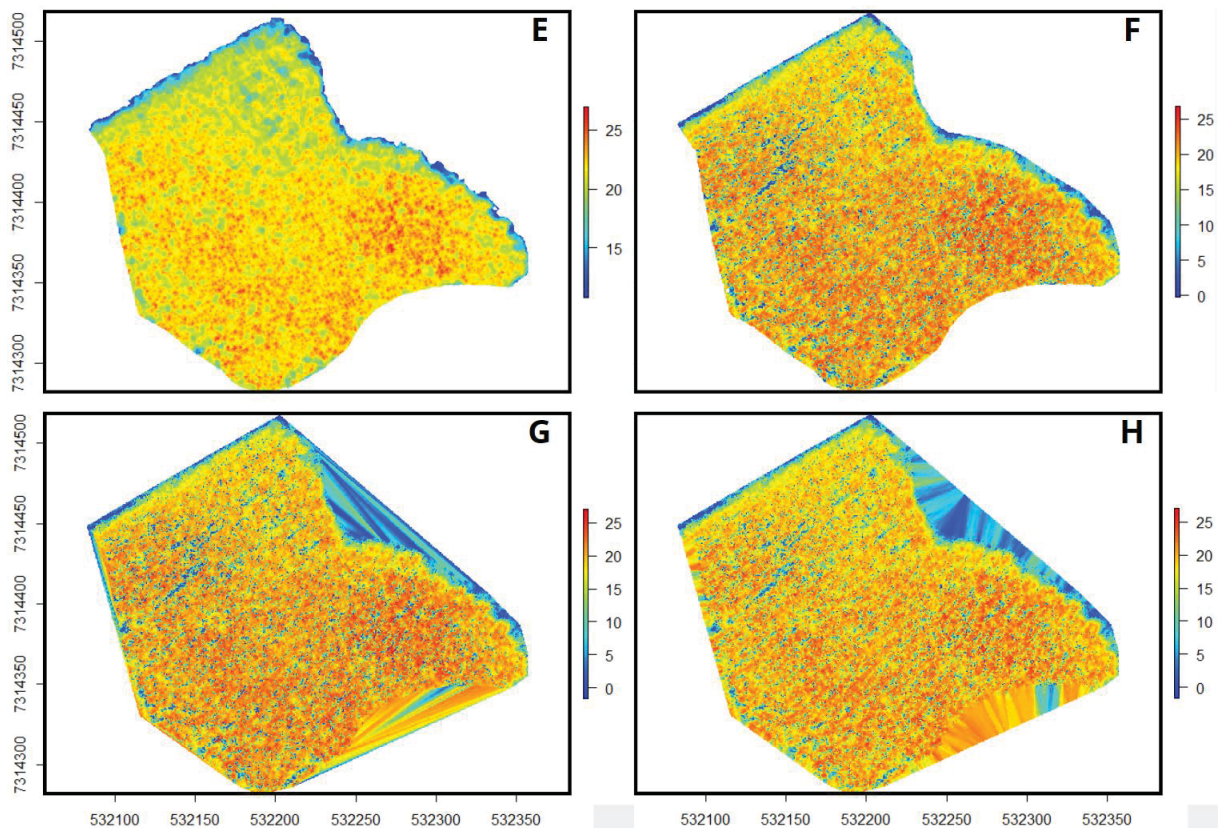
O algoritmo que aplica a interpolação por rede de triângulos irregulares livre de poços, tem como principal objetivo eliminar os espaços vazios que ocorrem no momento da transformação de dados LiDAR em imagens *raster*, situação que ocorre devido a presença de múltiplos retornos, consiste em construir vários modelos digitais parciais considerando apenas os primeiros retornos do pulso LiDAR em diferentes alturas, que são combinados mantendo o valor mais alto para cada posição planimétrica (x, y) a fim de gerar o modelo digital de copas final.

O usuário necessita definir os limites altimétricos antes de aplicar a rede de triângulos irregulares livre de poços, para tal foi implementado a automatização dessa determinação, baseada na amplitude da nuvem de pontos LiDAR e aplicado 5 limites, o primeiro a 90% da amplitude da nuvem, incrementando de modo decrescente em 10% até atingir a amplitude de 50% da nuvem, estes limites são convertidos em alturas

ou altitudes quais são aplicados no método para segmentar a nuvem e gerar os modelos digitais parciais.

As aplicações dos métodos de modelagem digital são apresentadas na Figura 27, que corresponde ao talhão D5A, onde algumas discrepâncias visuais podem ser observadas, o modelo digital E corresponde ao método baseado na rede de triângulos irregulares livre de poços (*pitfree*), F ao método da rede de triângulos irregulares com restrição de aresta (*dsmtin*), G ao método tradicional da rede de triângulos irregulares (*tin*) e H correspondente ao método interpolador ponderado inverso da distância (*idw*).

FIGURA 27 - COMPARATIVO ENTRE OS ALGORITMOS DE MODELAGEM DIGITAL, PARA O TALHÃO D5A.



FONTE: O Autor (2020).

4.3 DETECÇÃO E CONTAGEM DE ÁRVORES

Após o algoritmo implementado, o esforço computacional para a execução de todos os cenários de contagem nos 5 talhões, contabilizou 47 minutos e 30 segundos, retornando uma média de 9 minutos e 30 segundos por talhão e aproximadamente 6 segundos por cenário, visto que algumas execuções podem demandar mais tempo que outras. Os cenários foram executados em uma *Workstation* com processador Intel Xeon 2.6GHz, 32 GB de memória RAM e placa de aceleração gráfica.


4.3.1 Filtro de máxima local

O filtro de máxima local por aceitar uma gama maior de dados de entrada conta com 90 cenários diferentes, os resultados respectivos estão divididos por tipo de janela de busca. A janela fixa é baseada no espaçamento teórico do talhão e as janelas móveis em função da altura do dossel florestal.

4.3.1.1 Janela de busca fixa

A aplicação do filtro de máxima local, com janela de busca de dimensão fixa (2,5 m, em função do espaçamento teórico), considerando ambas as idades (10 e 15 anos) os testes na maioria, subestimaram o número de árvores por talhão, 82,67% foram subestimados, 0,67% superestimaram e 16,67% atingiram valores aderentes, como observado na Figura 28.

FIGURA 28 - DESEMPENHO DA CONTAGEM PARA O FILTRO DE MÁXIMA LOCAL COM JANELA DE DIMENSÃO FIXA.



FONTE: O Autor (2020).

Os piores cenários do filtro de máxima local com janela de busca fixa (cenários 4 e 14) identificaram 5,2% das árvores do talhão H1A, esses cenários tiveram como entrada modelos digitais de altura, construídos utilizando o interpolador baseado na rede de triângulos irregulares livre de poços (pitfree), o formato da janela de busca é quadrado, alterando apenas o método de classificação da nuvem de pontos (filtro morfológico progressivo e filtro simulador de tecidos).

O cenário 21 foi o que mais se aproximou do valor obtido via censo, identificando o correspondente a 100,4% do número total de árvores para o talhão D2A, nesse cenário o filtro de máxima local utiliza uma janela de dimensão fixa, de formato circular, e a entrada de dados é a nuvem de pontos sem classificação e consequentemente não normalizada.


4.3.1.2 Janela de busca móvel em função da altura

A janela de busca móvel, proporciona dois modos de dimensionamento, proporcional à altura do dossel e inversamente proporcional à altura do dossel, os resultados obtidos nas contagens utilizando as duas abordagens de dimensionamento da janela de busca são levemente semelhantes.

Na maioria, ambas as abordagens de dimensionamento subestimam o número de árvores, quando se utiliza como entrada superfícies referentes aos modelos digitais de alturas ou aos modelos digitais de elevação, a situação de comporta de modo inverso quando a entrada de dados são nuvens de pontos.

Com a janela de busca móvel, e dimensionamento em função de altura das arvores de modo proporcional, 82% dos cenários subestimaram o número de árvores por talhão, 10% superestimaram e 8% dos cenários atingiram condições aderentes, como observado na Figura 29.

FIGURA 29 - DESEMPENHO DA CONTAGEM PARA O FILTRO DE MÁXIMA LOCAL COM JANELA DE DIMENSÃO MÓVEL, PROPORCIONAL A ALTURA.




FONTE: O Autor (2020).

Para o dimensionamento da janela proporcional à altura do dossel florestal, os cenários 33, 34, 43 e 44, atingiram os menores índices de identificação de número de árvores, em média, identificaram 2,4% das árvores do talhão H1A, ambos os cenários utilizam como entrada modelos digitais de altura construídos pelo método de interpolação baseado na rede de triângulos irregulares livre de poços, divergindo somente no método de classificação (filtro morfológico progressivo e filtro simulador de tecidos) e no formato da janela de busca (circular e quadrada).

Foi verificado também a ocorrência de superestimativa, chegando a 160,3% no cenário 52 para o talhão D2A, nesse cenário o filtro utilizou uma janela circular e a entrada de dados foi uma nuvem de pontos não classificada e não normalizada.

A abordagem de dimensionamento móvel da janela de modo inversamente proporcional à altura do dossel, comportou-se de modo semelhante ao proporcional à altura, onde em 88% dos cenários o número de árvores por talhão foi subestimado, 3,33% superestimado e 8,67% dos cenários são aderentes, ilustrado na Figura 30.

FIGURA 30 - DESEMPENHO DA CONTAGEM PARA O FILTRO DE MÁXIMA LOCAL COM JANELA DE DIMENSÃO MÓVEL, INVERSAMENTE PROPORCIONAL A ALTURA.



FONTE: O Autor (2020).


Os piores desempenhos deram-se nos cenários que utilizaram modelos digitais de alturas gerados pelo método de interpolação baseado na rede de triângulos irregulares livre de poços, correspondente aos cenários 63, 64, 73 e 74, chegando a identificar apenas 2,6% das árvores do talhão H1A, alterando entre os cenários o formato da janela de busca (circular ou quadrado) e o método de classificação (filtro morfológico progressivo e o filtro simulador de tecidos).

A situação de superestimação atingiu o teto de 118,1% de identificação de árvores do talhão D2A, correspondente ao cenário 72, com entrada uma nuvem de pontos normalizada e previamente classificada pelo filtro simulador de tecidos, o filtro de máximos locais utilizou nesse cenário, uma janela de formato circular.

4.3.2 Segmentação por bacias hidrográficas

O método de identificação de árvores por bacias hidrográficas, que utiliza como entrada apenas modelos digitais de altura ou modelos digitais de elevação, em 66,67% dos cenários superestimou o número de árvores por talhão, e 33,33% dos cenários foram subestimados, nenhum cenário de comportou de modo aderente a determinação do número de árvores, como apresentado na Figura 31.

FIGURA 31 - DESEMPENHO DA CONTAGEM PARA A SEGMENTAÇÃO POR BACIAS HIDROGRÁFICAS.



FONTE: O Autor (2020).


Quando utilizado modelos digitais de altura interpolados pelo método *pitfree*, o algoritmo se comportou de modo a subestimar o número de árvores, correspondente aos cenários 91 e 95, identificando somente 5,9% das árvores do talhão H1A no cenário 91 e 6,0% no cenário 95.

As superestimações do método se comportaram de modo bem acentuado, como por exemplo no cenário 101, identificando de modo errôneo o correspondente a 718,9% o número de árvores para o talhão D5A.

4.3.3 Segmentação pelo filtro de máximos globais

A identificação e contagem de árvores utilizando a segmentação por máximos globais subestimou 33,33% dos cenários, 66,67% dos cenários foram classificados como aderentes, e não ocorreram situações de superestimação, conforme a Figura 32.

FIGURA 32 - DESEMPENHO DA CONTAGEM PARA A SEGMENTAÇÃO PELO FILTRO DE MÁXIMOS GLOBAIS.



FONTE: O Autor (2020).

A detecção mínima do método foi de 68% do talhão F9B, para o cenário 105, mesmo cenário onde ocorreu a maior acerto na detecção de árvores, porém para o talhão D2A, no qual o algoritmo foi capaz de identificar 93,8% das árvores, esse cenário fez uso de uma nuvem de pontos não classificada e não normalizada como entrada de dados.

Na média, o melhor cenário para o filtro de máximos globais, foi o cenário 104, o dado de entrada do método consistiu em uma nuvem de pontos normalizada e previamente classificada pelo filtro simulador de tecidos.

4.4 ALGORITMOS ADERENTES

Os resultados da contagem por algoritmos que atingiram acurácia menor que 80%, ou que superestimaram o número de árvores do talhão, foram considerados insatisfatórios e descartados para essa fase do trabalho, sendo considerados somente os resultados julgados como aderentes a todos os talhões simultaneamente. Para a definição do melhor algoritmo, a análise foi subdividida por idade ou combinações delas

Classificação dos algoritmos foi realizado com base no ordenamento do melhor resultado para o pior (para a Raiz do erro médio quadrático ($RMSE$), o Erro médio absoluto (MAE), o coeficiente de eficiência (E), o índice de concordância de Willmott (d) e o índice de desempenho (c)), onde os melhores resultados são

atribuídos a pesos maiores, a soma dos pesos determinou a classificação dos mesmos.

Os parâmetros citados foram recalculados para as situações onde utilizou-se somente uma das idades, devido a alteração das médias e do número de observações, os mesmos são apresentados no item apêndices deste trabalho (Tabelas 20 e 21).

4.4.1 Talhões com 10 e 15 anos de idade

Considerando os parâmetros de classificação, obteve-se somente um cenário aderente a todos os talhões simultaneamente para ambas as idades, o seu desempenho pode ser observado na Tabela 9.

TABELA 9 - ALGORITMO ADERENTE E PARÂMETROS DE AVALIAÇÃO PARA OS TALHÕES DE 10 E 15 ANOS DE IDADE.

Cenário	a (D2A)	a (D4A)	a (D5A)	a (F9B)	a (H1A)	RMSE	MAE	E	d	c
27	90,40%	84,40%	81,60%	80,70%	83,00%	18,4%	16,4%	0,809	0,945	0,941

Em que: a (X) = acurácia do talhão X; RMSE = Raiz do erro médio quadrático; MAE = Erro médio absoluto; E = Coeficiente de eficiência; d = Índice de concordância de Willmott; c = Índice de desempenho.

FONTE: O Autor (2020).

Para ambas as idades apenas o filtro de máxima local com janela de busca de dimensão fixa em formato circular aplicado ao modelo digital de elevação, construído pelo interpolador ponderado inverso da distância, atingiu as condições de acurácia para os 5 talhões examinados, apresentado na Tabela 10.

TABELA 9 - CENÁRIO COM DESEMPENHO SATISFATÓRIO PARA OS TALHÕES DE 10 E 15 ANOS DE IDADE.

Posição	Cenário	Algoritmo	Formato do dado de entrada	Dimensão da janela de busca	Formato da janela de busca	Método de classificação da nuvem de pontos	Normalização da nuvem de pontos	Método de modelagem digital
1	27	fml	MDE	fixa	Circular	-	-	idw

Em que: fml = filtro de máxima local; MDE = Modelo digital de elevação; idw = interpolador ponderado inverso da distância;

FONTE: O Autor (2020).

4.4.2 Talhões com 10 anos de idade

Dentre os algoritmos aderentes a todos os talhões de 10 anos simultaneamente e seguindo os critérios de classificação, temos os seguintes resultados e parâmetros utilizados na avaliação apresentados na Tabela 11.

TABELA 10 - ALGORITMOS ADERENTES E PARÂMETROS DE AVALIAÇÃO PARA OS TALHÕES DE 10 ANOS DE IDADE.

Posição	Cenário	a (F9B)	a (H1A)	RMSE	MAE	E	d	c
1	82	86,60%	90,30%	11,28%	11,28%	0,402	0,871	0,871
2	21	85,10%	88,40%	13,01%	13,01%	0,204	0,831	0,831
3	27	80,70%	83,00%	18,04%	17,98%	-0,531	0,736	0,736

Em que: a (X) = acurácia do talhão X; RMSE = Raiz do erro médio quadrático; MAE = Erro médio absoluto; E = Coeficiente de eficiência; d = Índice de concordância de Willmott; c = Índice de desempenho.

FONTE: O Autor (2020).

Provavelmente com o desempenho dos algoritmos prejudicado pela presença de árvores de maior altura nos talhões de 10 anos (F9B e H1A), as contagens satisfatórias resumiram-se no emprego do filtro de máxima local com janela de busca no formato circular. Os demais algoritmos (segmentação de bacias hidrográficas e pelo filtro de máximos globais) não atingiram os níveis de restrição previamente definidos, os algoritmos satisfatórios e respectivas classificações para os povoamentos com 10 anos de idade são apresentados na Tabela 12.

TABELA 11 – CLASSIFICAÇÃO DOS CENÁRIOS COM DESEMPENHO SATISFATÓRIO PARA OS TALHÕES COM 10 ANOS DE IDADE

Posição	Cenário	Algoritmo	Formato do dado de entrada	Dimensão da janela de busca	Formato da janela de busca	Método de classificação da nuvem de pontos	Normalização da nuvem de pontos	Método de modelagem digital
1	82	fml	NP	inv. prop. alt.	Circular	-	-	-
2	21	fml	NP	fixa	Circular	-	-	-
3	27	fml	MDE	fixa	Circular	-	-	idw

Em que: fml = filtro de máxima local; NP = Nuvem de pontos LiDAR; MDE = Modelo digital de elevação; inv. prop.alt = inversamente proporcional à altura; idw = interpolador ponderado inverso da distância; FONTE: O Autor (2020).

O cenário com melhor desempenho (cenário 82) consistiu na aplicação do filtro de máxima local, com janela de busca circular móvel inversamente proporcional à altura e tendo como entrada a nuvem de pontos bruta sem normalização, seguido do filtro de máxima local, com janela de busca de dimensão fixa, formato circular e como entrada de dados a nuvem de pontos sem normalização (cenário 21). E o filtro de máxima local com janela de busca de dimensão fixa em formato circular aplicado ao modelo digital de elevação, construído por interpolação baseado no interpolador inverso da distancia (cenário 27).

4.4.3 Talhões com 15 anos de idade

Para algoritmos aderentes a todos os talhões de 15 anos simultaneamente, atingiu-se as seguintes classificações em função dos resultados e parâmetros utilizados na avaliação apresentados na Tabela 13.

TABELA 13 - ALGORITMOS ADERENTES E PARÂMETROS DE AVALIAÇÃO PARA OS TALHÕES DE 15 ANOS DE IDADE

Posição	Cenário	a (D2A)	a (D4A)	a (D5A)	RMSE	MAE	E	d	c
1	11	99,4%	97,2%	84,3%	5,9%	4,7%	0,982	0,996	0,984
2	1	98,6%	97,0%	83,8%	6,2%	5,2%	0,980	0,995	0,990
3	41	96,2%	93,0%	84,1%	8,6%	7,9%	0,962	0,990	0,980
4	31	95,8%	92,8%	83,7%	8,9%	8,2%	0,959	0,989	0,980
5	105	93,8%	85,7%	91,9%	13,9%	10,9%	0,901	0,970	0,966
6	104	92,5%	83,8%	90,5%	15,8%	12,6%	0,871	0,961	0,956
7	103	92,4%	83,7%	90,7%	15,9%	12,6%	0,870	0,960	0,956
8	27	90,4%	84,4%	81,6%	16,4%	14,5%	0,861	0,960	0,950
9	17	88,1%	84,6%	81,3%	16,6%	15,1%	0,858	0,960	0,955
10	7	86,8%	84,7%	80,5%	16,8%	15,6%	0,854	0,959	0,956

Em que: a (X) = acurácia do talhão X; RMSE = Raiz do erro médio quadrático; MAE = Erro médio absoluto; E = Coeficiente de eficiência; d = Índice de concordância de Willmott; c = Índice de desempenho.

FONTE: O Autor (2020).

Os talhões com 15 anos apresentaram maior número de cenários considerados satisfatórios, em termos gerais, foram aderentes aos algoritmos de

detecção por máximos globais e pelo filtro de máxima local. A implementação da identificação de árvores, fazendo uso de algoritmos baseados em segmentação por bacias hidrográficas, não atingiu as restrições de acurácia para ser considerado satisfatório. Os cenários satisfatórios e suas classificações por desempenho são apresentados na Tabela 14.

TABELA 14 - CLASSIFICAÇÃO DOS CENÁRIOS COM DESEMPENHO SATISFATÓRIO PARA OS TALHÕES COM 15 ANOS DE IDADE

Posição	Cenário	Algoritmo	Formato do dado de entrada	Dimensão da janela de busca	Formato da janela de busca	Método de classificação da nuvem de pontos	Normalização da nuvem de pontos	Método de modelagem digital
1	11	fml	NP	fixa	Circular	csf	sim	-
2	1	fml	NP	fixa	Circular	pmf	sim	-
3	41	fml	NP	prop. alt.	Quadrada	csf	sim	-
4	31	fml	NP	prop. alt.	Quadrada	pmf	sim	-
5	105	fmg	NP	variável	Irregular	-	-	-
6	104	fmg	NP	variável	Irregular	csf	sim	-
7	103	fmg	NP	variável	Irregular	pmf	sim	-
8	27	fml	MDE	fixa	Circular	-	-	idw
9	17	fml	MDA	fixa	Circular	csf	sim	idw
10	7	fml	MDA	fixa	Circular	pmf	sim	idw

Em que: fml = filtro de máxima local; fmg = filtro de máximas globais; NP = Nuvem de pontos LiDAR; MDA = Modelo digital de altura; MDE = Modelo digital de elevação; prop.alt = proporcional à altura; fmp = filtro morfológico progressivo; csf = *cloth simulation filter* (filtro simulador de tecidos); idw = interpolador ponderado inverso da distância;

FONTE: O Autor (2020).

Para os talhões com 15 anos de idades, os 3 cenários com melhor desempenho consistiram na aplicação do filtro de máxima local, com janela de busca circular fixa e como entrada a nuvem de pontos normalizada e previamente classificada pelo filtro simulador de tecidos (cenário 11), no filtro de máxima local, com janela de busca de dimensão fixa, formato circular e como entrada de dados a nuvem de pontos normalizada pelo filtro morfológico progressivo (cenário 1), e no filtro de máxima local com janela de busca móvel com dimensionamento proporcional à altura em formato quadrado aplicado a nuvem de pontos normalizada pelo filtro simulador de tecidos (cenário 41).

5 DISCUSSÃO

Visto a complexidade dos povoamentos com copas entrelaçadas e idade próximas ao corte para a espécie *Pinus taeda* L., verificou-se que os algoritmos baseados em segmentação por bacias hidrográficas não são bons detectores de árvores. O método pode se comportar menos atraente ainda quando ocorrem árvores com alturas discrepantes (TANHUANPAA et al. 2016).

Vauhkonen et al. (2012) avaliaram algoritmos em diferentes condições florestais e concluíram que a estrutura da floresta afeta fortemente a performance dos algoritmos, dependendo o sucesso da detecção de árvores da densidade e do agrupamento das árvores.

As metodologias baseadas no filtro de máximas globais e principalmente no filtro de máxima locais apresentaram desempenho consideravelmente maior, aproximando-se dos valores obtidos via censo florestal, enaltecendo a coerência da identificação de árvores pelo filtro de máxima local (KAARTINEN et al. 2012).

A questão relacionada a densidade de pontos por m², obtida via levantamento LiDAR ainda demanda de aprofundamentos para a definição se é ou não correlacionada a acurácia das detecções de árvores, as diferenças entre densidades neste trabalho são muito baixas para analisar tal fator, que é considerado altamente influente na identificação de árvores por WANG et al. (2016). A densidade ideal é dependente do tamanho da árvore e espaçamento do povoamento, e espera-se que maiores densidades remetam a maior precisão de identificação (KAARTINEN et al. 2012). Em contrapartida é exposto que as características da floresta e escolha do método de identificação de árvores pode proporcionar maior impacto sobre a precisão, do que a densidade de pontos da nuvem LiDAR (KAARTINEN et al. 2008).

Somente o censo florestal não é suficiente para definir com certeza absoluta qual o melhor método de detecção ou qual a melhor densidade de pontos LiDAR para cada caso. Visto que por não existir redundância na contagem de árvores no censo florestal devido aos custos e tempo demandado, situação que não possibilita o cálculo de sua acurácia, precisão e analisar falso positivos ou falso negativos. Mensurações de qualquer grandeza podem estar associadas a erros, que no caso do censo florestal podem estar relacionadas a erros grosseiros ou acidentais, provenientes de erros de anotação ou causas aleatórias e que são de difícil identificação (GEMAEL, 2015).

Mesmo que a utilização de dados provenientes de sensoriamento remoto possua valores considerados elevados devido a tecnologia empregada (SANQUETTA et al., 2014), deve ser ressaltada a redução de trabalho em campo e o aumento da precisão nas estimativas florestais (KAARTINEN et al. 2012). A necessidade de uma análise de custos detalhada entre técnicas tradicionais e a identificação automática de árvores ainda se faz necessário (SILVA et al. 2016), porem para organizações onde os levantamentos LiDAR já fazem parte do processo produtivo, é altamente aconselhável o uso de técnicas de contagens automáticas.

6 CONCLUSÕES

A contagem automática de árvores por algoritmos, utilizando dados LiDAR aerotransportados de baixa densidade, comportou-se de modos distintos quando aplicados a uma mesma área, com uma gama de combinações expressiva (105 cenários possíveis), em que apenas 0,95% dos cenários implementados atingiram níveis satisfatórios de estimativa populacional, considerando ambas as idades.

Quando o desempenho foi analisado por idades separadamente, ficou explícito que a presença de árvores acima do dossel de interesse aliado a dados LiDAR de pulsos discretos, acaba prejudicando a determinação do número de árvores das áreas com plantio mais jovem (talhões com 10 anos de idades) onde apenas 2,9% dos cenários implementados atingiram níveis satisfatórios para a contagem automática de árvores, frente a 9,5% de aderência dos cenários nos talhões de idade maior (15 anos de idade) e sem a presença de árvores acima do dossel principal.

A contagem automática por algoritmos foi executada com a mínima interferência do usuário, onde o mesmo fornece apenas a nuvem de pontos LiDAR e o espaçamento teórico do povoamento, todos os demais parâmetros necessários para o correto funcionamento dos algoritmos utilizados são definidos automaticamente em função do espaçamento indicado e das dimensões da nuvem de pontos LiDAR, pelo motivo da mínima interferência do usuário os algoritmos testados resumiram-se no filtro de máxima local, segmentação por bacias hidrográficas e no filtro de máximos globais.

Para ambas as condições de idade (talhões com 10 e 15 anos) apenas um cenário comportou-se de modo aderente para todos os talhões, no qual resume-se na aplicação do filtro de máxima local com janela de busca fixa e de formato circular, na qual foi considerada o espaçamento teórico para o dimensionamento da janela, como dado de entrada um modelo digital de elevação, cuja a transformação em formato *raster*, viabilizada pelo interpolador inverso ponderado da distancia, o modelo digital de elevação foi proveniente da nuvem de pontos LiDAR não normalizada, este então considerado o método genérico independentemente da idade.

Para os talhões de 10 anos de idade, ocorreu a predominância de algoritmos que consistem na aplicação do filtro de máxima local com janela de busca circular, porem o melhor cenário apresenta as seguintes particularidades referente aos dados

de entrada e parâmetros de busca, aplicando uma janela de busca móvel inversamente proporcional à altura em uma nuvem de pontos LiDAR não normalizada.

Nos talhões de 15 anos de idade, ocorreu a aderência do filtro de máximas locais e do filtro de máximas globais, o com melhor acurácia trata-se do filtro de máximas locais com janela de busca circular com dimensão fixa em função do espaçamento teórico, como dado de entrada a nuvem de pontos LiDAR normalizada previamente classificada pelo método simulador de tecidos.

Para a área de estudo, visto as particularidades de cada povoamento, mesmo tratando-se da mesma espécie, o filtro de máxima local, com janela de busca circular, dimensão fixa, aplicado em um modelo digital de elevação, previamente construído pelo interpolador ponderado inverso da distância, é o mais acurado nas identificações de árvores e respeita as condições de aderência.

7 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Em trabalhos que sigam temáticas semelhantes, podem ser observados os seguintes quesitos:

Testar em um mesmo talhão, diferenças significativas de densidades para as nuvens de pontos ALS, com a finalidade de determinar a densidade ideal para a espécie e características do povoamento e viabilizar uma análise da correlação da densidade média de pontos com a acurácia da detecção.

Aplicar a metodologia em povoamentos com espaçamentos diferentes para verificar se os parâmetros definidos em função do espaçamento teórico são consistentes, ou necessitam de uma calibração, qual só é possível se aplicada a espaçamentos diferentes.

Realizar em conjunto um imageamento aéreo no espectro visível, pois as imagens aéreas são essenciais para uma avaliação completa da acurácia dos algoritmos implementados, assim como para a verificação de erros grosseiros na execução do censo florestal.

Utilizar dados LiDAR *full-waveform*, visando minimizar os efeitos causados por indivíduos dominantes sobre o dossel de interesse, os pulsos discretos inviabilizaram a contagem nos talhões com 10 anos de idade, devido a existência de indivíduos suprimidos pelos indivíduos dominantes.

Testar diferentes filtros de suavização para os modelos digitais, utilizando os mesmos algoritmos e metodologias de pré-processamento de dados aplicados neste trabalho, cada filtro de suavização testado proporcionará 84 novos cenários a serem avaliados.

REFERÊNCIAS

- ALIXANDRINI, M. J. **Estimativa da altura da vegetação utilizando dados airborne laser scanner**. 2005. 68 f. Dissertação (Mestrado em Engenharia Civil). Programa de Pós-Graduação em Engenharia Civil - PPGECC, Universidade Federal de Santa Catarina, Florianópolis (SC), 2005
- BARBOSA, L. J. **Deteção e extração de vegetação utilizando dados lidar: determinação de indivíduos e aglomerados**. 2017. 88 f. Dissertação (mestrado). Programa de Pós-Graduação em Ciências Cartográficas da FCT – Faculdade de Ciência e Tecnologia da UNESP – Universidade Estadual Paulista “Júlio de Mesquita Filho”. Presidente Prudente (SP), 2017.
- CAMARGO, A. de; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de agrometeorologia**, v. 5, n. 1, p. 89-97, 1997.
- CERQUEIRA, A. M. L. da G. **Recuperação de Facetas para Triangulação de Delaunay Conforme de Complexos Curvos**. 2010. 52 f. Dissertação de Mestrado, Departamento de Engenharia Elétrica, Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais. 2010.
- CHAO Y., WU T., WANG X. ZHENG G., The computation of Delaunay triangulation of LiDAR point cloud based on GPU, **23rd International Conference on Geoinformatics**, p. 1-4, Wuhan, 2015.
- CHEN, Q., BALDOCCHI, D.D., GONG, P., KELLY, M., Isolating individual trees in a savanna woodland using small footprint LIDAR data, **Photogrammetric Engineering & Remote Sensing**, v. 72 n. 8, p. 923-932. 2006.
- CHEN, S., TRUONG-HONG, L. C., O'KEEFFE, E., LAEFER, D., MANGINA, E. Outlier detection of point clouds generating from low-cost UAVs for bridge inspection. Life-Cycle Analysis and Assessment in Civil Engineering: Towards an Integrated Vision - **Proceedings of the 6th International Symposium on Life-Cycle Civil Engineering**, IALCCE 2018, p. 1969-1975, 2018.
- CHEN, Y. ZHU, X. An integrated GIS tool for automatic forest inventory estimates of Pinus radiata from LiDAR data. **GIScience and Remote Sensing**, n. 50, p. 667-689, 2013.
- CHEN, Y. ZHU, X. Site quality assessment of a Pinus radiata plantation in Victoria, Australia, using LiDAR technology. Southern. **Forests**, n. 74, p. 217-227, 2012.
- DALLA CORTE, Ana Paula et al. Measuring Individual Tree Diameter and Height Using GatorEye High-Density UAV-Lidar in an Integrated Crop-Livestock-Forest System. **Remote Sensing**, v. 12, n. 5, p. 863, 2020.
- DRESCH, G. **Avaliação automática de acurácia relativa de dados LiDAR aerotransportado**. 2015. 105 f. Dissertação (mestrado) - Universidade Federal do

Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas. Curitiba - PR, 2015. Disponível em: <http://hdl.handle.net/1884/40083>.

DRESCH, G.I; DOS SANTOS, D. R. Avaliação automática da acurácia relativa de dados LiDAR aerotransportado. **Boletim de Ciências Geodésicas**, v. 21, n. 4, dez. 2015. ISSN 1982-2170. Disponível em: <https://revistas.ufpr.br/bcg/article/view/44383>

ESPINDOLA, G. M., CÂMARA, G., REIS, I. A., BINS, L. S., MONTEIRO, A. M. Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3035-3040, 2006.

FERRAZ, A., SAATCHI, S., MALLET, C., MEYER, V. Lidar detection of individual tree size in tropical forests. **Remote Sensing of Environment**, v. 183, p. 318-333, 2016

FOTOTERRA **Projeto executivo**, metodologia para o Processamento dos Dados LiDAR e Produtos Gerados, 2018.

FRIEDLAENDER, H.; KOCH, B. First experience in the application of laser scanner data for the assessment of vertical and horizontal forest structures. **International archives of photogrammetry and remote sensing**, v. 33, p. 693-700, 2000.

GAVEAU, D. L.; HILL, R. A. Quantifying canopy height underestimation by laser pulse penetration in small-footprint airborne laser scanning data. **Canadian Journal of Remote Sensing**, v. 29, n. 5, p. 650-657, 2003.

GEMAEL, C.; MACHADO, A. M. L.; WANDRESEN, R. **Introdução ao ajustamento de observações: aplicações geodésicas**. 2ª edição - Curitiba: Ed. UFPR, 2015.

GIONGO, M., KOEHLER, H. S., DO AMARAL MACHADO, S., KIRCHNER, F. F., Marchetti, M. LiDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231, 2010.

GIRARDEAU-MONTAUT, D., ROUX, M., MARC, R., THIBAUT, G. Change detection on points cloud data acquired with a ground laser scanner. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. 36, n. part 3, p. W19, 2005.

HENTZ, Â. M. K. et al. Estimating forest uniformity in *Eucalyptus* spp. and *Pinus taeda* L. stands using field measurements and structure from motion point clouds generated from unmanned aerial vehicle (UAV) data collection. **Forest Systems**, v. 27, 2018.

HUANG, H; LI, X; CHEN, C. Individual tree crown detection and delineation from very-high-resolution UAV images based on bias field and marker-controlled watershed segmentation algorithms. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 7, p. 2253-2262, 2018.

INPE, SPRING. **Tutorial de geoprocessamento**. São José dos Campos, SP, Coordenação Geral de Observação da Terra, Departamento de Processamento de Imagem, 2006.

JAAKKOLA, A., et al. Autonomous Collection of Forest Field Reference-The Outlook and a First Step with UAV Laser Scanning. **Remote Sensing**, v. 9, n. 12, 2017.

KAARTINEN, H. et al. Accuracy of automatic tree extraction using airborne laser scanner data. **SilviLaser 2008**, v.1 n.1 p. 17-19, 2008.

KAARTINEN, H., et al. An International Comparison of Individual Tree Detection and Extraction Using Airborne Laser Scanning. **Remote Sensing**, n. 4, p. 950-974, 2012.

KATHURIA, A., et al. Development of an automated individual tree detection model using point cloud LiDAR data for accurate tree counts in a Pinus radiata plantation. **Australian Forestry**, n. 79, p. 126-136, 2016.

KE, Y.; QUACKENBUSH, L. J. A review of methods for automatic individual tree crown detection and delineation from passive remote sensing. **International Journal of Remote Sensing**, v. 32, n. 17, p. 4725–4747, 2011.

KHOSRAVIPOUR, A. at al. Generating pitfree canopy height models from airborne lidar. **Photogrammetric Engineering & Remote Sensing**, v. 80, n.9, p. 863-872, 2014.

KWAK, D.-A.; LEE, W.-K.; LEE, J.-H.; BIGING, G.; GONG, P. Detection of individual trees and estimation of tree height using LiDAR data. **Journal of Forest Research**, v. 12, n. 6, p. 425-434, 2007

LARANJA, D. C. F. **Estudo de parâmetros populacionais de plantios clonais de Eucalyptus spp. a partir de nuvens de pontos obtidos com escaneamento a laser aerotransportado**. 2016. 137 p. (ESALQ-CDD 634.9734 L318e). Dissertação (Mestrado em Recursos Florestais). Universidade de São Paulo, Piracicaba (SP), 2016.

LEGATES, D. R.; MCCABE JR, G. J. Evaluating the use of “goodness-of-fit” measures in hydrologic and hydroclimatic model validation. **Water Resources Research**, v. 35, n. 1, p. 233-241, 1999.

LEGLAND, D; ARGANDA-CARRERAS, I; ANDREY, P. MorphoLibJ: integrated library and plugins for mathematical morphology with ImageJ. **Bioinformatics**, v. 32, n. 22, p. 3532-3534, 2016.

LI, W. et al. A new method for segmenting individual trees from the lidar point cloud. **Photogrammetric Engineering & Remote Sensing**, v.78, n.1, p.75-84, 2012.

LINDBERG E., HOLMGREN J.,OLOFSSON K., OLSSON H. Estimation of stem attributes using a combination of terrestrial and airborne laser scanning. **Europe Journal Forest Resource**, v. 131, n. 6, p. 1917-1931, 2012

MACEDO, R. C. **Estimativa de volumétrica de povoamento clonal de Eucaliptos através de LASER scanner aerotransportado**. Dissertação de Mestrado pelo

Instituto Nacional de Pesquisas Espaciais, São José dos Campos (SP), 2009. Disponível em <http://urlib.net/sid.inpe.br/rep/sid.inpe.br/mtc-m18@80/2009/02>.

MACHADO, A. M. L. **Extração Automática de Contornos de Edificações Utilizando Imagem Gerada por Câmara Digital de Pequeno Formato e Dados LiDAR**. Tese (Doutorado em Ciências Geodésicas) – Setor de Ciências da Terra, Universidade Federal do Paraná, Curitiba (PR), 2006.

MARTINS, K., BLENKINSOPP C.E., ZANG J. Monitoring individual wave characteristics in the inner surf with a 2-dimensional laser scanner (LiDAR). **Sensors**, 2016, p. 1-11, <http://dx.doi.org/10.1155/2016/7965431>

MCGAUGHEY, R. J. **Fusion/LDV: Software for Lidar data analysis and visualization**. United States Department of Agriculture, Forest Service, Pacific Northwest Research Station, University of Washington, Seattle, p. 179, 2014.

MELLO, J. M. de; DINIZ, F. S.; OLIVEIRA, A. D. de; MELLO, C. R. de; SCOLFORO, J. R. S.; ACERBI JÚNIOR, F. W. Continuidade espacial para características dendrométricas (número de fustes e volume) em plantios de *Eucalyptus grandis*. **Revista Árvore**, Viçosa, v. 33, n. 1, p. 185-194, 2009.

MENDONÇA, R. L. **Filtragem de dados LIDAR para geração de modelo digital do terreno**. 2017. 72 f. Dissertação (Mestrado) - Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, Universidade Federal de Pernambuco, Dissertação de Mestrado, Recife (PE), 2017

MILLIKAN, P. H. K. et al. Automated individual tree detection in amazon tropical forest from airborne laser scanning data. **Cerne**, v. 25, n. 3, p. 273-282, 2019. ISSN 2317-6342. Disponível em: <http://www.cerne.ufla.br/site/index.php/CERNE/article/view/2104>.

MOHAN, M., et al. Individual Tree Detection from Unmanned Aerial Vehicle (UAV) Derived Canopy Height Model in an Open Canopy Mixed Conifer Forest. **Forests**, v. 8, n. 17, 2017.

OLIVEIRA, L. T. de; CARVALHO, L. M. T. de; FERREIRA, M. Z.; OLIVEIRA, T. C. de A.; ACERBI JUNIOR, F. W. Aplicação do LIDAR no inventário de florestas plantadas com *Eucalyptus* sp. para contagem de árvores. **Cerne**, Lavras, v. 18, p. 75-184, 2012.

OLIVEIRA, L., et al. Influência da idade na contagem de árvores de *Eucalyptus* sp. com dados de lidar. **Cerne**, v. 20, n. 4, p. 557-565, 2014.

PACKALÉN, P., et al. ALS-based estimation of plot volume and site index in a eucalyptus plantation with a nonlinear mixed-effect model that accounts for the clone effect. **Annals of Forest Science**, n. 68, p. 1085-1092, 2011.

PANAGIOTIDIS, D., et al. Determining tree height and crown diameter from high-resolution UAV imagery. **International Journal of Remote Sensing**, n. 38, 2017.

PAVAN, N. L. **Integração de fotogrametria e lidar: um estudo de caso para orientação indireta de fotografias com uso de telhados adjacentes como apoio de campo**. 2011. 72f. Dissertação (mestrado) - Universidade Federal do Paraná, Setor de Ciências da Terra, Programa de Pós-Graduação em Ciências Geodésicas. Curitiba (PR), 2011. Disponível em: <http://hdl.handle.net/1884/26417>.

PÉLLICO NETTO, S.; BRENA, D. A. **Inventário Florestal**. 1. ed. Curitiba, Curitiba, 1997.

POPESCU, S. C.; WYNNE, R. H. Seeing the trees in the forest. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 5, p. 589-604, 2004.

REUTEBUCH, S. E.; ANDERSEN, H. E.; MCGAUGHEY, R. Light detection and ranging (LIDAR): an emerging tool for multiple resource inventory. **Jornal of Forestry**, v. 103, n. 6, p. 286-292, 2005.

RIBAS, R. P.; ELMIRO, M. A. T. Individualização de árvores em ambiente florestal nativo utilizando métodos de segmentação em modelos digitais produzidos a partir da tecnologia LiDAR. **Revista Brasileira de Cartografia**, v. 65, n. 4, 11. 2013.

RODRIGUEZ, L. C. E.; POLIZEL, J. L.; FERRAZ, S. F. B.; ZONETE, M. F.; FERREIRA, M. Z. Inventário florestal com tecnologia laser aerotransportada de plantios de *Eucalyptus* spp. no Brasil. **Ambiência**, Guarapuava, v. 6, Edição Especial, p. 67-80, 2010.

RUSU, R., BLODOW, N., MARTON, Z., BEETZ, M., Aligning point cloud views using persistent feature histograms. **International Conference on Intelligent Robots and Systems (IROS)**, Nice, France, p. 3384-3391, 2008

SANQUETTA, C. R. et al. **Inventários Florestais: planejamento e execução**. 3. ed. Multi-Graphic Gráfica e editora, Curitiba, 2014.

SANTOS, K. S. M. **Deteção de árvores em povoamentos de *Pinus* spp. a partir de nuvens de pontos derivados de imagens ópticas de RPAS a partir da análise de máximo global**. 2018. 99 f. Dissertação (mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Curitiba (PR), 2018. Disponível em: <http://hdl.handle.net/1884/63714>.

SCHAWLOW, A.L., TOWNES, C.H. Infrared and Optical Maser. **Physical Review**, 112, 1940-1949, 1958.

SCOLFORO, J. R. S.; MELLO, J. M. de. **Inventário Florestal**. Lavras: Gráfica Universitária UFLA, 2006.

SILVA, A. G. P. da. **Estimativa da biomassa de lenho em povoamentos de *Eucalyptus grandis* baseada em estatísticas do perfil de dossel geradas por escaneamento a laser aerotransportado**. 2014. Dissertação (Mestrado em Recursos Florestais) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba (SP), 2014.

SILVA, C. A., et al. A principal component approach for predicting the stem volume in Eucalyptus plantations in Brazil using airborne LiDAR data. **Forestry**, n. 89, p. 422-433, 2016.

SILVA, C. A., et al. Imputation of Individual Longleaf Pine (*Pinus palustris* Mill.) Tree Attributes from Field and LiDAR Data. **Canadian Journal of Remote Sensing**, n. 42, p. 554-573, 2016.

SILVA, C. A., CROOKSTON, N. L., HUDAK, A. T., VIERLING, L. A., KLAUBERG, C., SILVA, M. C. A. Package 'rLiDAR'. LiDAR Data Processing and Visualization **The CRAN Project**, 2017.

SILVA, I.L.G.; SILVA, C.A.; KLAUBERG, C.; MELLO, J.M. Detecção de árvores individuais em área florestal mista de coníferas por meio de dados LiDAR aerotransportando. **Advances in Forestry Science**, Cuiabá, v. 4, n. 2, p. 107-112, 2017. Disponível em: <http://periodicoscientificos.ufmt.br/ojs/index.php/afor/article/view/4067/pdf>.

SILVA, M. N. **Aplicação de LASER scanner terrestre para determinação de variáveis dendrométricas em Pinus spp.** 2011. 126 f. Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal, Curitiba (PR), 2011.

SOILLE, P. VINCENT, L. M. Determining watersheds in digital pictures via flooding simulations. **Visual Communications and Image Processing'90: Fifth in a Series**. International Society for Optics and Photonics, v. 1360, p. 240-250, 1990.

STRAUB, C. KOCH, B. Estimating single tree stem volume of *Pinus sylvestris* using airborne laser scanner and multispectral line scanner data. **Remote Sensing**, n. 3, p. 929-944, 2011.

TANHUANPAA, T., et al. Evaluating the Performance of High-Altitude Aerial Image-Based Digital Surface Models in Detecting Individual Tree Crowns in Mature Boreal Forests. **Forests**, v. 7, n. 17, 2016.

VASTARANTA, M. Forest mapping and monitoring using active 3D remote sensing. **Dissertationes Forestales**, v. 144, p. 45, 2012.

VAUHKONEN, J. et al. Comparative testing of single-tree detection algorithms under different types of forest. **Forestry**, v. 85, n. 1, p. 27-40, 2012.

WALLACE, L.; LUCIEER, A.; WATSON, C. S. Evaluating Tree Detection and Segmentation Routines on Very High Resolution UAV LiDAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 12, p. 7619-7628, 2014.

WANG, L.; GONG, P.; BIGING, G. S. Individual tree-crown delineation and treetop detection in high-spatial-resolution aerial imagery. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 3, p. 351-357, 2004.

WANG, Y. S., et al. International Benchmarking of the Individual Tree Detection Methods for Modeling 3-D Canopy Structure for Silviculture and Forest Ecology Using Airborne Laser Scanning. **IEEE Transactions on Geoscience and Remote Sensing**, n. 54, p. 5011-5027, 2016.

WEHR, A.; LOHR, U. Airborne Laser Scanning – An Introduction and Overview. **ISPRS Journal of Photogrammetry & Remote Sensing**. v. 54, pp. 68-82. 1999.

WEST, P. W. **Tree and Forest Measurement**. Nova Iorque: Springer, 2015.

WULDER, M.; NIEMANN, K. O.; GOODENOUGH, D. Local maximum filtering for the Extraction of Tree Locations and Basal Area from High Spatial Resolution Imagery. **Remote Sensing of Environment**, v. 73, n. 0, p. 103–114, 2000.

YANG, C. S.; KAO, S. P.; LEE, F. B.; HUNG, P. S. Twelve different interpolation methods: a case study of Surfer 8.0. **Proceedings of ISPRS Congress** v. 20 p. 778–785, 2004

YU, X., et al. Assessment of Low Density Full-Waveform Airborne Laser Scanning for Individual Tree Detection and Tree Species Classification. **Forests**, n. 5, p. 1011-1031, 2014.

ZANDONÁ, D. F.; LINGNAU, C.; MÜLLER, M.; MARTINS, M. A. R. Avaliação da precisão altimétrica do mapeamento digital a laser em áreas de cobertura vegetal densa. **XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia - GO. Anais. São José dos Campos - SP: INPE. p. 757-762, 2005.

ZANDONÁ, D. F.; LINGNAU, C.; NAKAJIMA, N. Y. Varredura a Laser aerotransportado para estimativa de variáveis dendrométricas. **Scientia Forestalis**, Piracicaba, v. 36, n. 80, p. 295–306, 2008.

ZANDONA, D. F. **Potencial uso de dados laser scanner aerotransportado para estimativa de variáveis dendrométricas**. 2006. 82f. Dissertação (mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Curitiba (PR), 2006. Disponível em: <http://hdl.handle.net/1884/11999>.

ZHANG W. et al. An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation. **Remote Sensing**, v. 8, n. 6, p. 501, 2016.

ZHANG, J. et al. Seeing the forest from drones: Testing the potential of lightweight drones as a tool for long-term forest monitoring. **Biological Conservation**, v. 198, p. 60–69, 2016.

ZHANG, K.; CHEN, S. C.; WHITMAN, D.; SHYU, M. L.; YAN, J.; ZHANG, C. A progressive morphological filter for removing nonground measurements from airborne LIDAR data. **Geoscience and Remote Sensing, IEEE Transactions**, v. 41, n. 4, p. 872-882, 2003.

ZHAO, P., LU, D., WANG, G., WU, C., HUANG, Y., YU, S. Examining spectral reflectance saturation in Landsat imagery and corresponding solutions to improve forest aboveground biomass estimation. **Remote Sensing**, v. 8, n. 6, p. 469, 2016.

APÊNDICES

APÊNDICE 1 - CENÁRIOS E RESULTADOS DA IDENTIFICAÇÃO DE ÁRVORES PARA OS TALHÕES DE 10 ANOS DE IDADE

Cenário	a (D2A)	a (D4A)	a (D5A)	a (F9B)	a (H1A)	RMSEr	MAEr	E	d	c
1	98,6%	97,0%	83,8%	46,0%	10,5%	69,5%	43,3%	-1,725	0,478	0,000
2	79,1%	75,9%	69,6%	42,0%	9,4%	72,6%	53,3%	-1,977	0,477	0,000
3	55,5%	51,6%	55,9%	26,6%	5,4%	82,8%	68,0%	-2,876	0,446	0,005
4	45,3%	41,9%	46,2%	24,2%	5,2%	86,0%	73,1%	-3,174	0,445	0,003
5	80,7%	75,2%	76,5%	43,1%	9,1%	72,5%	52,5%	-1,967	0,469	0,001
6	62,5%	58,0%	59,4%	37,8%	7,9%	77,4%	61,9%	-2,382	0,471	0,000
7	86,8%	84,7%	80,5%	44,7%	10,1%	70,6%	48,4%	-1,814	0,473	0,000
8	64,7%	62,4%	62,0%	38,7%	8,4%	76,1%	60,0%	-2,270	0,475	0,000
9	74,7%	69,8%	70,6%	35,7%	6,7%	76,4%	57,5%	-2,299	0,455	0,004
10	57,9%	54,3%	56,7%	32,1%	6,0%	80,6%	65,6%	-2,671	0,457	0,002
11	99,4%	97,2%	84,3%	46,2%	10,5%	69,4%	43,1%	-1,721	0,477	0,000
12	79,6%	76,2%	70,2%	42,2%	9,5%	72,4%	53,0%	-1,964	0,477	0,000
13	56,2%	52,0%	56,8%	26,7%	5,4%	82,7%	67,8%	-2,863	0,445	0,006
14	45,6%	42,0%	47,3%	24,3%	5,2%	85,9%	72,9%	-3,166	0,444	0,003
15	82,0%	75,7%	78,2%	43,3%	9,1%	72,3%	52,0%	-1,956	0,467	0,002
16	63,5%	58,4%	62,0%	38,0%	7,9%	77,2%	61,4%	-2,365	0,469	0,000
17	88,1%	84,6%	81,3%	44,9%	10,2%	70,5%	48,1%	-1,804	0,471	0,000
18	65,5%	62,5%	62,7%	39,0%	8,5%	75,9%	59,7%	-2,255	0,474	0,000
19	75,5%	69,9%	70,9%	35,9%	6,8%	76,3%	57,3%	-2,287	0,454	0,004
20	58,5%	54,4%	57,5%	32,4%	6,0%	80,5%	65,3%	-2,659	0,456	0,002
21	100,4%	96,9%	84,1%	85,1%	88,4%	11,9%	9,4%	0,920	0,978	0,957
22	80,2%	75,9%	69,3%	73,3%	73,8%	27,8%	25,4%	0,563	0,878	0,874
23	71,0%	66,0%	64,1%	64,4%	63,9%	38,0%	34,6%	0,182	0,779	0,777
24	54,6%	50,9%	51,9%	53,9%	52,4%	51,5%	47,4%	-0,501	0,679	0,677
25	82,3%	75,6%	76,6%	75,2%	73,2%	27,3%	24,4%	0,579	0,877	0,875
26	62,4%	58,1%	58,7%	61,6%	58,3%	44,2%	40,4%	-0,104	0,732	0,729
27	90,4%	84,4%	81,6%	80,7%	83,0%	18,4%	16,4%	0,809	0,945	0,941
28	66,5%	62,4%	61,9%	64,2%	63,1%	39,8%	36,5%	0,106	0,767	0,765
29	75,4%	69,4%	69,7%	69,7%	67,7%	33,6%	30,3%	0,364	0,822	0,820
30	57,7%	53,7%	56,4%	58,4%	55,2%	48,0%	44,0%	-0,302	0,704	0,699
31	95,8%	92,8%	83,7%	43,6%	10,0%	70,4%	45,4%	-1,800	0,470	0,001
32	124,3%	123,0%	104,2%	47,5%	11,2%	70,0%	49,3%	-1,768	0,451	0,001
33	32,5%	15,4%	29,1%	17,7%	2,3%	96,1%	84,9%	-4,221	0,413	0,067
34	36,2%	17,4%	32,5%	18,7%	2,4%	95,1%	83,5%	-4,105	0,413	0,076
35	50,9%	23,3%	45,4%	28,5%	6,0%	88,5%	75,7%	-3,420	0,427	0,049
36	59,4%	28,0%	54,5%	32,2%	6,5%	85,7%	71,7%	-3,148	0,427	0,061
37	55,1%	26,5%	48,6%	30,4%	6,4%	86,8%	73,6%	-3,255	0,430	0,045
38	66,8%	32,6%	58,5%	33,6%	7,2%	83,6%	68,8%	-2,947	0,429	0,059
39	42,3%	21,0%	35,4%	23,2%	4,1%	91,9%	80,0%	-3,767	0,423	0,040
40	49,2%	24,3%	41,4%	25,0%	4,5%	90,0%	77,3%	-3,572	0,423	0,054

Cenário	a (D2A)	a (D4A)	a (D5A)	a (F9B)	a (H1A)	RMSEr	MAEr	E	d	c
41	96,2%	93,0%	84,1%	43,8%	10,0%	70,3%	45,2%	-1,795	0,470	0,001
42	126,9%	123,2%	105,2%	47,7%	11,2%	70,1%	49,7%	-1,772	0,447	0,002
43	34,2%	15,8%	29,4%	17,4%	2,4%	96,0%	84,7%	-4,202	0,412	0,074
44	38,3%	17,7%	32,2%	18,4%	2,4%	95,0%	83,2%	-4,095	0,412	0,082
45	52,1%	23,2%	46,4%	29,5%	6,0%	88,2%	75,3%	-3,393	0,426	0,051
46	60,4%	28,1%	55,4%	32,4%	6,5%	85,6%	71,4%	-3,136	0,426	0,066
47	55,8%	26,5%	48,5%	30,5%	6,4%	86,7%	73,5%	-3,250	0,430	0,046
48	67,8%	32,6%	58,7%	33,8%	7,2%	83,5%	68,6%	-2,940	0,429	0,061
49	42,9%	20,8%	35,9%	23,3%	4,1%	91,8%	79,9%	-3,765	0,422	0,044
50	50,0%	24,3%	41,5%	25,2%	4,4%	89,9%	77,2%	-3,570	0,422	0,056
51	119,3%	113,6%	96,5%	97,9%	104,6%	9,6%	7,8%	0,948	0,988	0,962
52	160,3%	150,8%	125,4%	124,9%	138,5%	44,1%	39,7%	-0,099	0,832	0,800
53	42,5%	20,3%	34,2%	50,4%	49,5%	64,8%	59,5%	-1,373	0,596	0,414
54	55,5%	27,3%	44,9%	62,1%	63,9%	53,3%	48,0%	-0,604	0,671	0,479
55	55,1%	24,2%	48,3%	60,8%	59,3%	56,3%	50,3%	-0,788	0,642	0,424
56	75,9%	34,7%	69,9%	79,9%	82,4%	39,7%	31,5%	0,109	0,799	0,540
57	60,5%	27,4%	50,8%	65,7%	66,9%	51,0%	45,1%	-0,471	0,690	0,470
58	96,0%	45,0%	81,4%	97,0%	105,9%	30,2%	17,9%	0,486	0,893	0,625
59	44,5%	21,2%	36,3%	54,0%	51,8%	62,6%	57,3%	-1,216	0,609	0,419
60	58,7%	28,5%	50,0%	67,5%	67,5%	50,2%	44,5%	-0,423	0,700	0,490
61	90,4%	87,1%	77,2%	48,2%	11,0%	69,1%	46,6%	-1,698	0,486	0,000
62	115,7%	113,9%	95,8%	54,1%	12,4%	67,0%	44,1%	-1,538	0,482	0,000
63	32,7%	15,5%	29,4%	20,0%	2,6%	95,4%	84,2%	-4,141	0,416	0,046
64	35,7%	17,1%	32,3%	20,9%	2,6%	94,5%	83,0%	-4,050	0,416	0,055
65	59,1%	26,5%	53,9%	38,3%	8,0%	84,0%	70,3%	-2,983	0,438	0,026
66	69,6%	32,1%	65,9%	41,0%	8,7%	81,1%	65,7%	-2,715	0,435	0,049
67	65,7%	31,4%	58,4%	42,3%	9,6%	80,7%	66,4%	-2,683	0,447	0,016
68	82,8%	40,5%	74,8%	46,0%	10,6%	76,6%	59,6%	-2,317	0,441	0,042
69	46,5%	23,5%	39,4%	28,6%	5,3%	89,1%	76,9%	-3,483	0,431	0,021
70	53,6%	27,1%	46,8%	29,8%	5,6%	87,3%	74,2%	-3,306	0,430	0,041
71	90,9%	87,3%	77,7%	48,4%	11,0%	69,1%	46,4%	-1,694	0,485	0,000
72	118,1%	114,0%	96,5%	54,3%	12,5%	67,0%	44,3%	-1,534	0,479	0,000
73	34,4%	15,8%	29,6%	19,6%	2,6%	95,3%	84,0%	-4,133	0,415	0,055
74	37,6%	17,4%	32,1%	20,5%	2,7%	94,4%	82,8%	-4,037	0,415	0,061
75	59,7%	26,5%	54,8%	38,4%	8,0%	83,9%	70,1%	-2,977	0,437	0,029
76	70,4%	32,3%	66,5%	41,1%	8,7%	81,0%	65,5%	-2,706	0,434	0,052
77	66,4%	31,3%	57,9%	42,4%	9,6%	80,7%	66,4%	-2,683	0,447	0,016
78	83,9%	40,3%	74,5%	46,1%	10,6%	76,6%	59,5%	-2,319	0,440	0,044
79	47,1%	23,0%	39,5%	28,9%	5,2%	89,2%	76,9%	-3,492	0,430	0,024
80	54,6%	26,8%	46,8%	30,1%	5,5%	87,3%	74,1%	-3,308	0,429	0,044
81	81,1%	77,0%	70,0%	74,4%	75,2%	26,5%	24,3%	0,603	0,889	0,885
82	102,0%	98,4%	85,1%	86,6%	90,3%	10,3%	8,2%	0,940	0,984	0,964
83	42,5%	20,3%	34,2%	50,4%	49,5%	64,8%	59,5%	-1,373	0,596	0,414
84	47,6%	23,1%	37,7%	53,9%	54,1%	60,8%	55,6%	-1,091	0,620	0,439
85	55,1%	24,2%	48,3%	60,8%	59,3%	56,3%	50,3%	-0,788	0,642	0,424

Cenário	a (D2A)	a (D4A)	a (D5A)	a (F9B)	a (H1A)	RMSEr	MAEr	E	d	c
86	61,7%	27,8%	55,4%	65,6%	66,1%	50,9%	44,7%	-0,465	0,684	0,460
87	60,5%	27,4%	50,8%	65,7%	66,9%	51,0%	45,1%	-0,471	0,690	0,470
88	70,0%	32,5%	59,2%	72,3%	76,4%	44,0%	37,4%	-0,095	0,760	0,528
89	44,5%	21,2%	36,3%	54,0%	51,8%	62,6%	57,3%	-1,216	0,609	0,419
90	50,1%	24,0%	40,7%	58,0%	56,3%	58,6%	53,2%	-0,938	0,633	0,441
91	60,7%	55,3%	66,5%	30,3%	5,9%	80,7%	64,6%	-2,675	0,445	0,010
92	212,4%	189,6%	280,1%	79,3%	16,1%	90,1%	82,2%	-3,585	0,204	0,019
93	626,7%	602,1%	701,2%	131,2%	27,6%	331,2%	267,0%	-60,982	0,090	0,006
94	174,5%	163,2%	221,2%	59,1%	11,6%	80,6%	72,4%	-2,666	0,207	0,016
95	60,9%	55,6%	67,6%	30,3%	6,0%	80,5%	64,4%	-2,663	0,445	0,010
96	212,7%	189,7%	282,7%	79,8%	16,2%	90,3%	82,4%	-3,603	0,203	0,020
97	628,6%	603,4%	705,6%	131,8%	27,8%	332,3%	268,0%	-61,390	0,090	0,006
98	175,2%	163,3%	221,3%	59,4%	11,7%	80,5%	72,4%	-2,664	0,207	0,016
99	132,0%	129,5%	124,1%	126,8%	128,7%	31,0%	28,4%	0,458	0,905	0,904
100	224,7%	196,0%	291,8%	210,0%	197,9%	115,5%	111,7%	-6,541	0,515	0,508
101	646,6%	611,0%	718,9%	557,0%	560,7%	525,2%	496,1%	-154,812	0,166	0,164
102	181,2%	168,6%	226,9%	172,2%	159,0%	75,1%	73,0%	-2,187	0,643	0,639
103	92,4%	83,7%	90,7%	74,3%	79,5%	21,9%	18,2%	0,730	0,918	0,902
104	92,5%	83,8%	90,5%	74,3%	80,5%	21,4%	17,9%	0,742	0,922	0,906
105	93,8%	85,7%	91,9%	68,0%	69,2%	28,7%	22,2%	0,535	0,847	0,781

Em que: a (X) = acurácia do talhão X; RMSE = Raiz do erro médio quadrático; MAE = Erro médio absoluto; E = Coeficiente de eficiência; d = Índice de concordância de Willmott; c = Índice de desempenho.

FONTE: O Autor (2020).

APÊNDICE 2 - CENÁRIOS E RESULTADOS DA IDENTIFICAÇÃO DE ÁRVORES PARA OS TALHÕES DE 10 ANOS DE IDADE

Cenário	a (F9B)	a (H1A)	RMSE	MAE	E	d	c
1	46,0%	10,5%	79,51%	74,34%	-28,723	0,219	0,219
2	42,0%	9,4%	81,34%	76,68%	-30,103	0,220	0,220
3	26,6%	5,4%	88,55%	85,55%	-35,859	0,223	0,223
4	24,2%	5,2%	89,42%	86,69%	-36,590	0,224	0,224
5	43,1%	9,1%	81,27%	76,38%	-30,054	0,218	0,218
6	37,8%	7,9%	83,55%	79,33%	-31,814	0,221	0,221
7	44,7%	10,1%	80,13%	75,12%	-29,188	0,219	0,219
8	38,7%	8,4%	82,94%	78,66%	-31,340	0,221	0,221
9	35,7%	6,7%	84,99%	80,91%	-32,956	0,219	0,219
10	32,1%	6,0%	86,50%	82,85%	-34,177	0,221	0,221
11	46,2%	10,5%	79,46%	74,25%	-28,686	0,219	0,219
12	42,2%	9,5%	81,21%	76,53%	-30,007	0,220	0,220
13	26,7%	5,4%	88,52%	85,50%	-35,834	0,223	0,223
14	24,3%	5,2%	89,39%	86,64%	-36,564	0,224	0,224

Cenário	a (F9B)	a (H1A)	RMSE	MAE	E	d	c
15	43,3%	9,1%	81,22%	76,29%	-30,015	0,218	0,218
16	38,0%	7,9%	83,49%	79,24%	-31,772	0,220	0,220
17	44,9%	10,2%	80,01%	74,98%	-29,095	0,219	0,219
18	39,0%	8,5%	82,79%	78,47%	-31,221	0,221	0,221
19	35,9%	6,8%	84,86%	80,77%	-32,855	0,219	0,219
20	32,4%	6,0%	86,42%	82,73%	-34,108	0,220	0,220
21	85,1%	88,4%	13,01%	13,01%	0,204	0,831	0,831
22	73,3%	73,8%	26,66%	26,41%	-2,341	0,605	0,605
23	64,4%	63,9%	36,30%	35,89%	-5,196	0,499	0,499
24	53,9%	52,4%	47,57%	46,96%	-9,638	0,410	0,410
25	75,2%	73,2%	26,38%	25,95%	-2,271	0,600	0,600
26	61,6%	58,3%	40,98%	40,29%	-6,896	0,451	0,451
27	80,7%	83,0%	18,04%	17,98%	-0,531	0,736	0,736
28	64,2%	63,1%	36,90%	36,43%	-5,400	0,492	0,492
29	69,7%	67,7%	31,93%	31,45%	-3,794	0,536	0,536
30	58,4%	55,2%	44,15%	43,43%	-8,162	0,429	0,429
31	43,6%	10,0%	80,49%	75,65%	-29,454	0,220	0,220
32	47,5%	11,2%	78,63%	73,30%	-28,064	0,219	0,219
33	17,7%	2,3%	93,47%	91,12%	-40,076	0,221	0,221
34	18,7%	2,4%	93,08%	90,64%	-39,735	0,221	0,221
35	28,5%	6,0%	87,55%	84,39%	-35,038	0,224	0,224
36	32,2%	6,5%	86,12%	82,52%	-33,865	0,222	0,222
37	30,4%	6,4%	86,71%	83,35%	-34,347	0,223	0,223
38	33,6%	7,2%	85,22%	81,53%	-33,140	0,223	0,223
39	23,2%	4,1%	90,49%	87,74%	-37,499	0,222	0,222
40	25,0%	4,5%	89,66%	86,74%	-36,795	0,222	0,222
41	43,8%	10,0%	80,43%	75,56%	-29,416	0,220	0,220
42	47,7%	11,2%	78,58%	73,21%	-28,028	0,219	0,219
43	17,4%	2,4%	93,50%	91,19%	-40,100	0,221	0,221
44	18,4%	2,4%	93,18%	90,77%	-39,819	0,221	0,221
45	29,5%	6,0%	87,26%	83,96%	-34,794	0,223	0,223
46	32,4%	6,5%	86,06%	82,44%	-33,818	0,222	0,222
47	30,5%	6,4%	86,68%	83,31%	-34,323	0,223	0,223
48	33,8%	7,2%	85,16%	81,44%	-33,095	0,222	0,222
49	23,3%	4,1%	90,46%	87,70%	-37,473	0,222	0,222
50	25,2%	4,4%	89,67%	86,72%	-36,802	0,222	0,222
51	97,9%	104,6%	3,94%	3,53%	0,927	0,986	0,986
52	124,9%	138,5%	34,63%	32,69%	-4,638	0,588	0,588
53	50,4%	49,5%	50,71%	50,12%	-11,090	0,392	0,392
54	62,1%	63,9%	37,14%	36,87%	-5,486	0,498	0,498
55	60,8%	59,3%	40,60%	40,06%	-6,748	0,460	0,460
56	79,9%	82,4%	18,73%	18,67%	-0,649	0,725	0,725
57	65,7%	66,9%	33,89%	33,61%	-4,399	0,527	0,527
58	97,0%	105,9%	5,11%	4,66%	0,877	0,977	0,977
59	54,0%	51,8%	47,93%	47,26%	-9,799	0,406	0,406

Cenário	a (F9B)	a (H1A)	RMSE	MAE	E	d	c
60	67,5%	67,5%	32,84%	32,50%	-4,071	0,534	0,534
61	48,2%	11,0%	78,61%	73,11%	-28,048	0,217	0,217
62	54,1%	12,4%	76,20%	69,79%	-26,297	0,213	0,213
63	20,0%	2,6%	92,53%	89,97%	-39,255	0,220	0,220
64	20,9%	2,6%	92,25%	89,58%	-39,009	0,220	0,220
65	38,3%	8,0%	83,34%	79,06%	-31,651	0,220	0,220
66	41,0%	8,7%	82,11%	77,51%	-30,696	0,219	0,219
67	42,3%	9,6%	81,11%	76,43%	-29,931	0,221	0,221
68	46,0%	10,6%	79,44%	74,28%	-28,668	0,219	0,219
69	28,6%	5,3%	88,02%	84,75%	-35,421	0,222	0,222
70	29,8%	5,6%	87,45%	84,06%	-34,955	0,221	0,221
71	48,4%	11,0%	78,56%	73,03%	-28,013	0,217	0,217
72	54,3%	12,5%	76,08%	69,65%	-26,211	0,213	0,213
73	19,6%	2,6%	92,66%	90,14%	-39,365	0,220	0,220
74	20,5%	2,7%	92,31%	89,70%	-39,058	0,220	0,220
75	38,4%	8,0%	83,31%	79,02%	-31,630	0,220	0,220
76	41,1%	8,7%	82,08%	77,46%	-30,676	0,219	0,219
77	42,4%	9,6%	81,09%	76,39%	-29,912	0,221	0,221
78	46,1%	10,6%	79,41%	74,24%	-28,649	0,219	0,219
79	28,9%	5,2%	88,00%	84,68%	-35,406	0,221	0,221
80	30,1%	5,5%	87,44%	83,99%	-34,941	0,221	0,221
81	74,4%	75,2%	25,35%	25,14%	-2,022	0,623	0,623
82	86,6%	90,3%	11,28%	11,28%	0,402	0,871	0,871
83	50,4%	49,5%	50,71%	50,12%	-11,090	0,392	0,392
84	53,9%	54,1%	46,46%	45,99%	-9,147	0,422	0,422
85	60,8%	59,3%	40,60%	40,06%	-6,748	0,460	0,460
86	65,6%	66,1%	34,44%	34,11%	-4,576	0,520	0,520
87	65,7%	66,9%	33,89%	33,61%	-4,399	0,527	0,527
88	72,3%	76,4%	25,41%	25,35%	-2,035	0,633	0,633
89	54,0%	51,8%	47,93%	47,26%	-9,799	0,406	0,406
90	58,0%	56,3%	43,56%	42,97%	-7,919	0,437	0,437
91	30,3%	5,9%	87,09%	83,68%	-34,660	0,222	0,222
92	79,3%	16,1%	69,12%	56,91%	-21,460	0,165	0,165
93	131,2%	27,6%	61,61%	54,80%	-16,847	0,000	0,000
94	59,1%	11,6%	75,76%	68,11%	-25,987	0,201	0,201
95	30,3%	6,0%	87,02%	83,62%	-34,602	0,222	0,222
96	79,8%	16,2%	68,99%	56,64%	-21,373	0,163	0,163
97	131,8%	27,8%	61,57%	54,95%	-16,823	0,000	0,000
98	59,4%	11,7%	75,63%	67,93%	-25,890	0,201	0,201
99	126,8%	128,7%	28,33%	27,89%	-2,774	0,633	0,633
100	210,0%	197,9%	103,47%	103,07%	-49,332	0,257	0,257
101	557,0%	560,7%	464,24%	459,12%	-1012,222	0,068	0,068
102	172,2%	159,0%	64,71%	64,64%	-18,683	0,364	0,364
103	74,3%	79,5%	22,73%	22,72%	-1,430	0,673	0,673
104	74,3%	80,5%	22,15%	22,15%	-1,306	0,685	0,685

Cenário	a (F9B)	a (H1A)	RMSE	MAE	E	d	c
105	68,0%	69,2%	31,56%	31,31%	-3,684	0,551	0,551

Em que: a (X) = acurácia do talhão X; RMSE = Raiz do erro médio quadrático; MAE = Erro médio absoluto; E = Coeficiente de eficiência; d = Índice de concordância de Willmott; c = Índice de desempenho.

FONTE: O Autor (2020).

APÊNDICE 3 - CENÁRIOS E RESULTADOS DA IDENTIFICAÇÃO DE ÁRVORES PARA OS TALHÕES DE 15 ANOS DE IDADE.

Cenário	a (D2A)	a (D4A)	a (D5A)	RMSE	MAE	E	d	c
1	98,6%	97,0%	83,8%	6,2%	5,2%	0,980	0,995	0,990
2	79,1%	75,9%	69,6%	26,5%	24,5%	0,638	0,896	0,886
3	55,5%	51,6%	55,9%	51,7%	46,5%	-0,379	0,659	0,658
4	45,3%	41,9%	46,2%	62,4%	56,3%	-1,008	0,594	0,593
5	80,7%	75,2%	76,5%	26,0%	23,1%	0,652	0,894	0,889
6	62,5%	58,0%	59,4%	44,9%	40,5%	-0,040	0,708	0,704
7	86,8%	84,7%	80,5%	16,8%	15,6%	0,854	0,959	0,956
8	64,7%	62,4%	62,0%	40,7%	37,1%	0,146	0,744	0,742
9	74,7%	69,8%	70,6%	32,0%	28,7%	0,471	0,838	0,833
10	57,9%	54,3%	56,7%	49,0%	44,3%	-0,239	0,679	0,677
11	99,4%	97,2%	84,3%	5,9%	4,7%	0,982	0,996	0,984
12	79,6%	76,2%	70,2%	26,1%	24,1%	0,649	0,899	0,889
13	56,2%	52,0%	56,8%	51,2%	45,9%	-0,350	0,661	0,661
14	45,6%	42,0%	47,3%	62,1%	56,0%	-0,992	0,594	0,594
15	82,0%	75,7%	78,2%	25,2%	22,1%	0,673	0,899	0,894
16	63,5%	58,4%	62,0%	44,1%	39,5%	-0,005	0,711	0,708
17	88,1%	84,6%	81,3%	16,6%	15,1%	0,858	0,960	0,955
18	65,5%	62,5%	62,7%	40,4%	36,7%	0,159	0,745	0,743
19	75,5%	69,9%	70,9%	31,8%	28,4%	0,479	0,839	0,833
20	58,5%	54,4%	57,5%	48,7%	43,9%	-0,225	0,680	0,678
21	100,4%	96,9%	84,1%	6,1%	4,9%	0,981	0,995	0,980
22	80,2%	75,9%	69,3%	26,4%	24,2%	0,642	0,896	0,883
23	71,0%	66,0%	64,1%	36,4%	33,0%	0,315	0,793	0,784
24	54,6%	50,9%	51,9%	52,8%	47,9%	-0,440	0,655	0,652
25	82,3%	75,6%	76,6%	25,4%	22,4%	0,667	0,898	0,890
26	62,4%	58,1%	58,7%	44,9%	40,6%	-0,040	0,709	0,705
27	90,4%	84,4%	81,6%	16,4%	14,5%	0,861	0,960	0,950
28	66,5%	62,4%	61,9%	40,4%	36,6%	0,159	0,745	0,740
29	75,4%	69,4%	69,7%	32,3%	28,9%	0,461	0,834	0,826
30	57,7%	53,7%	56,4%	49,5%	44,7%	-0,267	0,675	0,673
31	95,8%	92,8%	83,7%	8,9%	8,2%	0,959	0,989	0,980
32	124,3%	123,0%	104,2%	24,2%	19,7%	0,698	0,945	0,934
33	32,5%	15,4%	29,1%	88,0%	77,3%	-2,994	0,457	0,044
34	36,2%	17,4%	32,5%	85,4%	74,6%	-2,763	0,464	0,056

Cenário	a (D2A)	a (D4A)	a (D5A)	RMSE	MAE	E	d	c
35	50,9%	23,3%	45,4%	77,1%	65,0%	-2,066	0,485	0,025
36	59,4%	28,0%	54,5%	71,2%	58,4%	-1,616	0,502	0,042
37	55,1%	26,5%	48,6%	73,5%	61,5%	-1,788	0,500	0,062
38	66,8%	32,6%	58,5%	66,0%	53,2%	-1,249	0,526	0,079
39	42,3%	21,0%	35,4%	81,2%	70,5%	-2,399	0,481	0,089
40	49,2%	24,3%	41,4%	76,8%	65,7%	-2,044	0,494	0,086
41	96,2%	93,0%	84,1%	8,6%	7,9%	0,962	0,990	0,980
42	126,9%	123,2%	105,2%	25,0%	20,7%	0,678	0,942	0,927
43	34,2%	15,8%	29,4%	87,3%	76,6%	-2,936	0,459	0,031
44	38,3%	17,7%	32,2%	84,8%	73,9%	-2,714	0,466	0,034
45	52,1%	23,2%	46,4%	76,9%	64,5%	-2,054	0,483	0,013
46	60,4%	28,1%	55,4%	70,9%	57,9%	-1,596	0,502	0,033
47	55,8%	26,5%	48,5%	73,4%	61,4%	-1,782	0,500	0,052
48	67,8%	32,6%	58,7%	65,9%	52,9%	-1,241	0,525	0,066
49	42,9%	20,8%	35,9%	81,2%	70,3%	-2,401	0,479	0,068
50	50,0%	24,3%	41,5%	76,7%	65,5%	-2,035	0,494	0,072
51	119,3%	113,6%	96,5%	15,5%	13,1%	0,876	0,975	0,953
52	160,3%	150,8%	125,4%	55,5%	48,4%	-0,592	0,809	0,785
53	42,5%	20,3%	34,2%	81,8%	71,0%	-2,455	0,478	0,058
54	55,5%	27,3%	44,9%	73,1%	61,7%	-1,756	0,508	0,086
55	55,1%	24,2%	48,3%	75,5%	62,8%	-1,943	0,487	0,010
56	75,9%	34,7%	69,9%	62,6%	47,4%	-1,019	0,522	0,023
57	60,5%	27,4%	50,8%	71,9%	59,2%	-1,666	0,502	0,026
58	96,0%	45,0%	81,4%	51,5%	34,2%	-0,371	0,567	0,050
59	44,5%	21,2%	36,3%	80,6%	69,6%	-2,350	0,481	0,056
60	58,7%	28,5%	50,0%	71,2%	59,2%	-1,616	0,510	0,073
61	90,4%	87,1%	77,2%	14,9%	14,0%	0,885	0,969	0,956
62	115,7%	113,9%	95,8%	14,9%	12,5%	0,886	0,977	0,964
63	32,7%	15,5%	29,4%	87,8%	77,2%	-2,981	0,457	0,044
64	35,7%	17,1%	32,3%	85,8%	74,9%	-2,794	0,463	0,052
65	59,1%	26,5%	53,9%	72,6%	59,4%	-1,720	0,494	0,014
66	69,6%	32,1%	65,9%	65,7%	51,2%	-1,227	0,512	0,025
67	65,7%	31,4%	58,4%	67,2%	54,1%	-1,331	0,518	0,058
68	82,8%	40,5%	74,8%	56,5%	41,5%	-0,649	0,554	0,084
69	46,5%	23,5%	39,4%	78,1%	67,2%	-2,144	0,491	0,108
70	53,6%	27,1%	46,8%	73,3%	62,0%	-1,776	0,505	0,113
71	90,9%	87,3%	77,7%	14,6%	13,6%	0,889	0,970	0,957
72	118,1%	114,0%	96,5%	15,5%	13,0%	0,876	0,975	0,957
73	34,4%	15,8%	29,6%	87,3%	76,5%	-2,931	0,458	0,028
74	37,6%	17,4%	32,1%	85,2%	74,3%	-2,746	0,465	0,033
75	59,7%	26,5%	54,8%	72,5%	59,1%	-1,709	0,493	0,010
76	70,4%	32,3%	66,5%	65,4%	50,8%	-1,207	0,513	0,022
77	66,4%	31,3%	57,9%	67,3%	54,1%	-1,334	0,518	0,048
78	83,9%	40,3%	74,5%	56,7%	41,3%	-0,656	0,552	0,066
79	47,1%	23,0%	39,5%	78,4%	67,3%	-2,170	0,488	0,075

Cenário	a (D2A)	a (D4A)	a (D5A)	RMSE	MAE	E	d	c
80	54,6%	26,8%	46,8%	73,5%	61,8%	-1,785	0,503	0,082
81	81,1%	77,0%	70,0%	25,2%	23,3%	0,671	0,906	0,893
82	102,0%	98,4%	85,1%	5,3%	4,3%	0,985	0,996	0,981
83	42,5%	20,3%	34,2%	81,8%	71,0%	-2,455	0,478	0,058
84	47,6%	23,1%	37,7%	78,4%	67,5%	-2,171	0,490	0,072
85	55,1%	24,2%	48,3%	75,5%	62,8%	-1,943	0,487	0,010
86	61,7%	27,8%	55,4%	71,0%	57,7%	-1,604	0,500	0,018
87	60,5%	27,4%	50,8%	71,9%	59,2%	-1,666	0,502	0,026
88	70,0%	32,5%	59,2%	65,7%	52,2%	-1,230	0,523	0,040
89	44,5%	21,2%	36,3%	80,6%	69,6%	-2,350	0,481	0,056
90	50,1%	24,0%	40,7%	77,0%	65,7%	-2,059	0,493	0,062
91	60,7%	55,3%	66,5%	46,8%	41,1%	-0,128	0,683	0,682
92	212,4%	189,6%	280,1%	115,7%	113,4%	-5,902	0,555	0,526
93	626,7%	602,1%	701,2%	564,8%	528,1%	-163,559	0,181	0,181
94	174,5%	163,2%	221,2%	79,6%	77,6%	-2,267	0,676	0,653
95	60,9%	55,6%	67,6%	46,4%	40,6%	-0,110	0,684	0,683
96	212,7%	189,7%	282,7%	116,3%	114,1%	-5,973	0,553	0,521
97	628,6%	603,4%	705,6%	566,7%	530,1%	-164,679	0,181	0,180
98	175,2%	163,3%	221,3%	79,8%	77,8%	-2,285	0,675	0,653
99	132,0%	129,5%	124,1%	32,2%	29,1%	0,464	0,909	0,906
100	224,7%	196,0%	291,8%	124,6%	122,4%	-7,013	0,530	0,508
101	646,6%	611,0%	718,9%	577,8%	541,6%	-171,226	0,177	0,177
102	181,2%	168,6%	226,9%	85,6%	83,4%	-2,783	0,655	0,636
103	92,4%	83,7%	90,7%	15,9%	12,6%	0,870	0,960	0,956
104	92,5%	83,8%	90,5%	15,8%	12,6%	0,871	0,961	0,956
105	93,8%	85,7%	91,9%	13,9%	10,9%	0,901	0,970	0,966

Em que: a (X) = acurácia do talhão X; RMSE = Raiz do erro médio quadrático; MAE = Erro médio absoluto; E = Coeficiente de eficiência; d = Índice de concordância de Willmott; c = Índice de desempenho.

FONTE: O Autor (2020).